



UNIVERSIDADE DE BRASÍLIA

FACULDADE DE DIREITO

Curso de Graduação em Direito

JOÃO VICTOR DE ASSIS BRASIL RIBEIRO COELHO

APLICAÇÕES E IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NO DIREITO

Brasília

2017

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE DIREITO

Aplicações e Implicações da Inteligência Artificial no Direito

Autor: João Victor de Assis Brasil Ribeiro Coelho

Orientador: Henrique Araújo Costa

Monografia final de conclusão do curso de graduação apresentada como requisito parcial à obtenção do título de bacharel em Direito pela Universidade de Brasília, desenvolvida sob a orientação do Prof. Dr. Henrique Araújo Costa.

Brasília

2017

TERMO DE APROVAÇÃO

JOÃO VICTOR DE ASSIS BRASIL RIBEIRO COELHO

APLICAÇÕES E IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NO DIREITO

Monografia apresentada como requisito parcial à obtenção do grau de Bacharela em Direito pela Faculdade de Direito da Universidade de Brasília – UnB.

Brasília, 5 de dezembro de 2017.

Prof. Dr. Henrique Araújo Costa

Professor Orientador

Prof. Dr. Ricardo Fernandes Paixão

Membro da banca examinadora

Profa. Dra. Taynara Tiemi Ono

Membro da banca examinadora

Sumário

I. INTRODUÇÃO	7
II. PANORAMA	8
a. Judiciário Brasileiro.....	8
b. Inteligência Artificial	12
i. Um breve histórico	12
ii. Entendendo a Tecnologia.....	16
iii. Aplicações Gerais	28
iv. Aplicações no Direito.....	29
III. LEGAL LABS – DRA. LUZIA	37
a. Objetivo e Definição de Escopo	38
b. Obtenção de Dados	39
c. Organização e Pré-processamento de dados	40
d. Amostragem dos Dados	42
e. Aprendizado e Resultados	43
f. Fechamento	44
IV. IMPACTOS SOCIAIS DA TECNOLOGIA.....	45
a. Empregos e Automação	45
b. Implementação: Ritmo e Desafios.....	48
c. Preparando-se para Ruptura	53
i. O Novo Mercado de Trabalho.....	53
ii. Formação Educacional e Profissional	54
V. CONCLUSÃO	56
VI. REFERÊNCIAS	58

ABSTRAÇÃO

O presente trabalho tem por objetivo analisar as características, aplicações e implicações dos avanços recentes em tecnologia de Inteligência Artificial no campo jurídico, acompanhando o desenvolvimento do *software* Dra. Luzia, voltado a análise de processos judiciais de Execução fiscal da Procuradoria-Geral do Distrito Federal, iniciado por *startup* localizada em Brasília, além de analisar programas já em utilização que empregam tecnologias similares e seus potenciais impactos sobre a sociedade e mercado de trabalho.

Palavras Chave: Inteligência Artificial, Machine Learning, Redes Neurais, Dra. Luzia, Automação.

ABSTRACT

The present work aims to analyze the characteristics, applications and implications of the recent advances of Artificial Intelligence technology in the legal field, following the development of the *software* Dra. Luzia, focused on analyzing legal enforcement procedures of Distrito Federal's Attorney General, developed by a *startup* located in Brasília; and also to analyze I.A. programs already in utilization and its impacts over society and labor market.

Keywords: Artificial Intelligence, Machine Learning, Neural Networks, Dra. Luzia, Automation.

I. INTRODUÇÃO

Ricardo Fernandes, atuava como professor de Educação Física, até decidir largar a profissão e se aventurar em concursos públicos, visando os bons salários e a estabilidade econômica proporcionada. Após participar de seu primeiro certame, notou afinidade e gosto para a área jurídica, decidindo iniciar graduação em Direito e seguir com os estudos. No mês de sua formatura, dezembro de 2006, foi publicado edital para o concurso da Procuradoria-Geral do Distrito Federal, no qual foi aprovado após meses de árduo estudo e preparação. Desde então, Ricardo trabalha como Procurador.

Após anos atuando na área de Execução Fiscal, notou que o excessivo número de processos pendentes apenas se engrandecia com o tempo. Apesar dos esforços dos servidores, a velocidade de resolução e andamento dos casos não era rápida o suficiente para reduzir a quantidade acumulada, dada a notória morosidade judicial brasileira, e insuficiente progresso na resolução de casos em relação ao número de novos casos que surgiam e se amontoavam.

Foi no ano de 2016 que tomou ciência das recentes tecnologias e avanços na área de Inteligência Artificial (“I.A.”) e teve a ideia de aplicá-las em sua área de atuação.

O campo de I.A. é extremamente complexo e se viu estagnado por anos, apesar de muito investimento e pesquisa. Contudo, hoje se vê sob nova luz. Em face dos últimos avanços em neurociência, processamento computacional, análise e coleta em massa de dados, pesquisadores recentemente se viram munidos de ferramentas capazes de proporcionar novos e significativos avanços na área. O potencial da tecnologia se revelou tal que o interesse e investimento explodiram nos últimos cinco anos. Hoje não há empresa de tecnologia atuante em nível internacional que não possua departamento dedicado à área, e nota-se verdadeira corrida em escala global pelo seu aprimoramento.

Ciente do potencial da tecnologia, Ricardo montou equipe para embarcar no tsunami iminente, visando se antecipar às mudanças que afetarão sua área de atuação e o mercado. O presente trabalho acompanha o desenvolvimento do *software* pela equipe, localizada em Brasília, que visa aumentar a produtividade do trabalho de diversos servidores e contribuir para a solução do problema de ineficiência que a muito assola o serviço público e a prestação jurisdicional,

também adentrando na análise de programas similares sendo já sendo aplicados na área e seus impactos.

II. PANORAMA

a. Judiciário Brasileiro

O judiciário brasileiro é notoriamente reconhecido pela sua lentidão, ineficiência e alto volume de processos. O sistema é o mais saturado do mundo, tendo o TJSP como maior Tribunal em quantidade de processos. Apesar dos esforços administrativos e normativos - como a introdução do princípio da celeridade e razoável duração do processo pela Emenda Constitucional 45/2004 e os recentes dispositivos legais trazidos, com Novo Código de Processo Civil (Lei 13.105/15), Lei da Mediação (Lei 13.140/15) e Nova Arbitragem (Lei 13.129/15), que reduzem o número de recursos, primam por resoluções não contenciosas e por uma prestação jurisdicional mais eficiente - a morosidade persiste.

O tempo médio de tramitação dos processos pendentes na Justiça Comum Estadual é de 5.3 anos na fase de conhecimento em 1º Grau, 2.5 anos em 2º Grau e de 7.5 anos em Execução. Nos processos não pendentes é de 3 anos na fase de conhecimento em 1º Grau, 1 ano em 2º Grau e de 3.3 anos na Execução¹. Não há como se considerar devido e adequado um provimento jurisdicional que toma anos para efetivar direitos dos cidadãos.

Tal lentidão e ineficiência são atribuíveis a fatores diversos, notadamente ao excessivo leque de recursos processuais; ao baixo número de servidores públicos e juízes em proporção ao número de processos²; a precariedade e baixo investimento em infraestrutura e tecnologia; a uma burocracia ineficiente, complexa e corrupta; e a uma cultura de alta litigância – estimulada pela

¹ CNJ – Justiça em Números, 2017, pg. 39. Disponível em <http://www.cnj.jus.br/programas-e-acoas/pj-justica-em-numeros>. Acesso em 10.10.2017.

² 6 O número total de colaboradores (força de trabalho) era, em 2016, de 442.345, sendo 18.011 Magistrados; 279.013 Servidores e 145.321 Auxiliares, cf. CNJ, Justiça em Números, 2017, pg. 35. Disponível em <http://www.cnj.jus.br/programas-e-acoas/pj-justica-em-numeros>. Acesso em 13.10.2017.

gratuidade do acesso à justiça advinda da Constituição de 88, associada a um aumento expressivo no número de processos em tramitação³.

O ano de 2016 se encerrou com o exorbitante número de 79.7 milhões de processos em tramitação, apresentando um aumento de 7.6 milhões (9.5%) de processos em estoque desde 2014⁴. A Justiça Estadual é responsável por grande parte desses números, concentrando 80% dos processos pendentes e 69% da demanda judicial. O gráfico abaixo⁵ revela que o número de processos pendentes apenas tem crescido desde 2009, totalizando um aumento de 31,2% no período, correspondente a um acréscimo de 18.9 milhões de processos.




Fig.1 – Série Histórica da Movimentação Processual

Fonte: (Justiça em Números, 2017 – CNJ; <http://www.cnj.jus.br/programas-e-acoes/pj-justica-em-numeros>)

³ No ano de 1988, o número estimado de processos em andamento no judiciário era próximo a 400 mil. Uma década depois, esse número saltou para 3 milhões. Em 2003, primeiro ano da publicação do relatório Justiça em Números pelo CNJ, o número já ultrapassava um total de 10 milhões, seguindo um aumento para 70 milhões em 2008 e 100 milhões em 2014. (Disponível em <http://www.cnj.jus.br/programas-e-acoes/pj-justica-em-numeros>, acesso em 10.10.2017). Anteriormente ao ano de 2003, as referências são esparsas e desencontradas. Utilizou-se especialmente as pesquisas de VIANNA, Luiz Werneck et al., op. cit. A partir de 2003, as informações acima se encontram disponíveis em <http://www.cnj.jus.br/programas-e-acoes/pj-justica-em-numeros>, acesso em 10.10.2017.

⁴ O número de processos em 2014 e 2015 era de 72.1 milhões e 74 milhões respectivamente, apresentando aumento de 3% e 7.7% em relação aos relativos anos anteriores. CNJ, Justiça em Números, anos 2016 e 2017.

⁵ Gráfico: Série Histórica da Movimentação Processual no Poder Judiciário; Justiça em Números; 2017; CNJ

De 2014 para 2015, o índice de produtividade dos magistrados e servidores da área judiciária cresceu na taxa de 3,7% e 3,9%, respectivamente; apresentando leve retração de 0.75% em 2016⁶. Tais taxa de produtividade permitiram que a justiça estancasse o influxo de processos nesses últimos três anos, julgando número próximo ao de processos entrantes⁷, como se pode observar no gráfico. Mesmo nessas circunstâncias, não se está próximo de atingir eficiência anual grande o suficiente para lidar com a quantidade de processos ainda pendentes, que somam de 73 a 79.6 milhões para o mesmo período.

Dentre as razões para tal, dá-se especial atenção ao impacto negativo gerado pela fase de execução nos dados de litigiosidade do Poder Judiciário brasileiro, que além de corresponder alto volume de processos, apresenta altíssima taxa de congestionamento. Para bem ilustrar o desafio a ser enfrentado, dos cerca de 80 milhões de processos pendentes de baixa no final do ano de 2016, 40 milhões (51,1%) se referiam à fase de execução. Essa fase representa 53%, 49% e 42% dos acervos das Justiças Estadual, Federal e Trabalhista, respectivamente. Destaca-se que dentre as execuções pendentes, 82% (32 milhões) estão concentrados na Justiça Estadual.

Tal fenômeno se mostra preocupante, uma vez que grande parte do problema de efetividade da tutela jurisdicional não se encontra na fase de conhecimento, isto é, na própria resolução do objeto litigioso. Na situação corrente, de pouco adianta promover esforços para a rápida solução do mérito, uma vez que o Judiciário não consegue promover a execução das prestações de maneira eficiente. O decurso exagerado do tempo necessário para resolução apenas deturpa o sistema de justiça, beneficiando credores e impondo sobre devedores o ônus da morosidade.

O NCPC deu passo importante para promover uma execução mais equilibrada, ao estabelecer dentro de suas disposições a necessidade de dotar o credor de mecanismos ágeis e efetivos de satisfação de seus direitos com a menor onerosidade possível para o devedor. Contudo, por si só não é capaz de resolver as inúmeras deficiências sistêmicas que contaminam e lerdam o Judiciário.

⁶ A digitalização dos processos é um dos fatores que tem contribuído para a maior eficiência pública. Em 2009, apenas 12.8% dos novos processos em 1º grau eram processados eletronicamente; em 2016 o número foi de expressivos 73.3%.

⁷ No período de 2014 a 2016, 21 a 28,8 milhões de casos novos chegaram ao Judiciário em cada ano. Número muito próximo de julgamentos ocorreu no mesmo período, especialmente em 2015 e 2016.

Dos processos em fase de execução, elenca-se que os de natureza fiscal são os principais responsáveis pela alta taxa de congestionamento no Judiciário. Esses correspondem a 38% do total de casos pendentes e a 75% das execuções, sendo dotados de uma taxa de congestionamento de 91%, a maior entre todos os tipos de processos. Isso quer dizer que a cada 100 processos de execução fiscal tramitados em 2016, somente 9 foram baixados⁸. A maioria desses está na Justiça Estadual, com 86% dos casos, seguida pela Justiça Federal, com 14% dos casos; sendo que, em ambos os segmentos, a execução fiscal é a responsável por 42% dos casos pendentes.

É válido ressaltar que desde 2012 houve queda nas execuções fiscais iniciadas, com uma queda de 21% no ano de 2015. Entretanto, o acervo de execução continua subindo, uma vez que o total de processos baixados também caiu no Judiciário, na taxa de 6.1%.

Nesse contexto, observa-se que a situação judiciária atual é preocupante, dado o colossal número de processos pendentes de resolução, o alto fluxo de entrada de novos processos e a ausência ações ou propostas pelo poder público para tentar reverter ou minimizá-la num futuro próximo.

A conjuntura atual se mostra propícia a adoção de soluções como as de Inteligência Artificial, não só pela ausência de alternativas capazes de promover rápido e necessário incremento na eficiência da prestação jurisdicional, como pelo crescimento e consolidação de ecossistema favorável a adoção da tecnologia.

Em 2016, o judiciário apresentou despesa total de R\$ 84 bilhões, dos quais 2.5 bilhões (3%) foram referentes a despesas em contratos e aquisições em informática. Apesar de o número não ser expressivo em face do total, a série histórica de gastos com informática revela tendência de crescimento, apresentando aumento de 10,7% só no último ano. Em 2009, a despesa na área fora de R\$ 1.2 bilhões, menos da metade do gasto atual, e desde então apresenta crescimento de 17,1% ao ano. Tais dados indicam que o poder público possui recursos e disposição a adotar novas soluções em tecnologia da informação.

⁸ Consideram-se baixados os processos:

- a) Remetidos para outros órgãos judiciais competentes, desde que vinculados a tribunais diferentes;
- b) Remetidos para as instâncias superiores ou inferiores;
- c) Arquivados definitivamente;
- d) Em que houve decisões que transitaram em julgado e iniciou-se a liquidação, cumprimento ou execução.

A elevação da despesa na área pode ser interpretada como resultado da crescente digitalização dos processos. Em 2009, apenas 12.8% e 0.2% dos novos processos em 1º e 2º grau foram processados eletronicamente; já em 2016 os números subiram para expressivos 73.3% e 48.3% - e a tendência é de aumento. A predominância de ecossistema digital propulsiona o potencial de tecnologias de I.A., facilitando sua integração, desenvolvimento e aprimoramento.

É em meio a esse cenário, e à luz dos recentes avanços na área de I.A., que começam a surgir ações de iniciativa privada como a realizada pelo Professor Ricardo Fernandes e sua equipe. Cientes do potencial da tecnologia, e visando amenizar e solucionar as adversidades que hoje assolam o judiciário, trabalham na elaboração de resposta inteligente para munir o serviço público com ferramentas inovadoras, eficientes e a muito bem vindas.

b. Inteligência Artificial

i. Um breve histórico

Apesar de a I.A. ter se tornado o alvo recente dos holofotes internacionais em razão de impressionantes conquistas, deve-se notar que o campo é milenar, e seu conceito tem gênese na antiguidade⁹. A ambição de compreender e criar inteligência acompanha o ser humano desde então, que a passos lentos vêm se aproximando da sonhada concretude. No decorrer do último século, nomes famosos contribuíram com peças importantes para o desenvolvimento do campo^{10 11}, notadamente com estudos em computação, lógica, matemática e neurociência, fundamentais para estruturação da tecnologia nos moldes atuais.

⁹ Lendas e histórias descreviam seres artificiais imbuídos de inteligência ou consciência criados por mestres-artesãos, representando manifestação de um desejo antigo de forjar deuses - MCCORDUCK, Pamela, *Machines Who Think* (2a ed.), Natick, MA: A. K. Peters, 2004.

¹⁰ Alan Turing apresentou tese nos anos 30 que indicava que qualquer forma de raciocínio matemático dedutivo poderia ser imitado a partir da manipulação de inputs simples como 0s e 1s. Em 1950, especulou em uma publicação sobre a possibilidade de “máquinas pensantes”, desenvolvendo o conhecido Teste de Turing para testar a habilidade de uma máquina de simular inteligência ao conversar com um humano por meio de um teleimpressor, sem ser por ele identificada como tal. Seus trabalhos foram suficientes para refutar as principais objeções a possibilidade que ventilara, e seu teste tido como a primeira proposta séria no campo da filosofia da I.A.

¹¹ Bertrand Russel, em conjunto com Alfred North Whitehead, publicou a obra *Principia Mathematica* em 1913, dedicada a estabelecer axiomas e regras de inferência em lógica simbólica pelos quais todas as verdades matemáticas poderiam ser comprovadas. Tal tentativa demonstrou imperfeições ao se revelar incapaz de resolver teoremas de incompletude, como o proposto por Kurt GÖDEL em 1931.

O período de 1950 a 1970, conhecido como *anos de ouro* da I.A., foi marcado por passos importantes, como o início de estudos em Redes Neurais¹², desenvolvimento de algoritmos de “pesquisa”¹³, de “micromundos”¹⁴, de linguagem natural¹⁵, e início da aplicação de I.A. em jogos¹⁶. No ano de 1956 o campo passou a ser formalmente chamado de *Inteligência Artificial*¹⁷.

Também foi nesse período que a relação entre as áreas de Inteligência Artificial e direito teve início. Ao final dos anos 40, pesquisadores teorizaram e anteciparam diversas das possibilidades de aplicação de I.A. ao direito¹⁸; contudo, foi apenas na década de 70 que iniciativas práticas começaram a tomar vida, com destaque dos projetos LEGOL¹⁹ e TAXMAN²⁰. A década seguinte trouxe iniciativas importantes voltadas a revisão contratual²¹ e formalização de

¹² Tais pesquisas, lideradas por Walter PITTS e Warren McCulloch, idealizavam neurônios artificiais capazes de executar funções lógicas simples. Descriviam que neurônios variavam do estado de "desligado" para "ligado" a partir de estímulos externos ou de processo de ativação em cadeia por neurônios vizinhos. Foram responsáveis por dar início à chamada linha *conexionista*, caracterizada pela modelagem da inteligência humana por meio de simulações dos componentes e conexões do cérebro.

¹³ Programas voltados à solução de problemas de álgebra e geometria por tentativa e erro, com destaque do Sistema GPS (“General Problem Solver”), desenvolvido por Allen Newell e Herbert Simon.

¹⁴ Programas voltados a reproduzir artificialmente corpos e leis físicas em um ambiente digital.

¹⁵ Programas voltados a desenvolver redes semânticas capazes de se comunicar em línguas como o inglês;

¹⁶ O ano de 1951 foi marcado pela primeira aplicação de I.A. em jogos, especificamente em jogos de tabuleiros simples, na Universidade de Manchester. Programa de damas, desenvolvido por Arthur Samuel no final da década de 50, foi o primeiro capaz de desafiar propriamente um jogador de nível amador. A aplicação de I.A. em jogos vêm desde então sendo um parâmetro de progresso da tecnologia. - SCHAEFFER, Jonathan. *One Jump Ahead: Challenging Human Supremacy in Checkers, 1997-2009*, Springer, Capítulo 6.

¹⁷ A nomenclatura se deu por sugestão de John McCarthy ao final do Projeto de Pesquisa de Verão de Dartmouth, na Universidade de New Hampshire nos Estados Unidos. Essa conferência reuniu os principais nomes na área por oito semanas para trabalhar o tema. Sua premissa era a de que “todo aspecto de aprendizado ou característica de inteligência pode ser tão precisamente descrito que uma máquina pode ser feita para simulá-lo”.

¹⁸ Os estudos mais notáveis foram os desenvolvidos por Lee LOEVINGER em “Jurimetrics -The Next Step Forward”, de 1948; Layman ALLEN em “Symbolic logic: A razor-edged tool for drafting and interpreting legal documents”, 1956; e L. MEHL em “Automation in the Legal World: From the Machine Processing of Legal Information to the” Law Machine, Mechanisation of Thought Processes”, 1958.

¹⁹ Conduzido por Ronald Stamper na *London School of Economics* de 1976 a 1980. Seu objetivo era criar técnicas aperfeiçoadas para análise e especificação de sistemas administrativos e de processamento de dados, a partir da tradução de textos legais para linguagens de lógica formal que os representassem de maneira clara e precisa, posteriormente utilizando-as como base para um Programa Especialista. O projeto falhou por não conseguir fazer a tradução de textos legais complexos, muito técnicos ou que sofreram várias emendas. - STAMPER, Ronald K. *The LEGOL 1 prototype system and language*; *The Computer Journal* 20.2 (1977), pgs. 102-108.; *Knowledge-Based Systems and Legal Applications*.

²⁰ Conduzido por L. Thorne McCarthy em 1977 na Universidade de Harvard. Seu objetivo era desenvolver programa capaz de produzir análise das consequências tributárias de transações corporativas a partir de modelos de casos concretos de tributação corporativa e conceitos presentes no Código Interno de Faturamento dos Estados Unidos (*United States Internal Revenue Code*) – NIBLETT, Brian. *Computer Science and Law*. 1980.

²¹ GARDNER, Anne. *The design of a legal analysis program*, 1983.

legislação²², além de convenções e oficinas para discutir métodos de aplicação da tecnologia ao meio jurídico.

Nesse período, dentre os eventos mais relevantes da aplicação de I.A. ao Direito, elenca-se a instituição da bienal Convenção Internacional de I.A. e Direito (ICAL) em 1987, que se tornou palco das principais discussões e publicações sobre o tema. A Convenção findou por originar a Associação Internacional de I.A. e Direito (IAAIL) - que se tornou responsável pela organização das Convenções posteriores - e do Diário de I.A. e Direito, que teve sua primeira publicação em 1992. Em 1988 tiveram início as Conferências de JURIX na Europa, organizadas pela Fundação Jurix de Sistemas Baseados em Conhecimento Legal, que rapidamente tomaram proporção internacional²³.

Os progressos na área de I.A. foram marcados por picos de interesse e volatilidade nos investimentos. O campo passou por dois grandes momentos de estagnação e falta de capital, conhecidos como Invernos da I.A., ocorridos nos períodos de 1974 a 1980²⁴ e 1987 a 1993²⁵. Foram

²² SERGOT, Marek J. The British Nationality Act as a logic program. Communications of the ACM, 1986, pg. 370–386.

²³ Desde 2007 tem sido sediada no Japão e organizada pela Sociedade Japonesa de I.A.

²⁴ Os principais fatores responsáveis pelo *Primeiro Inverno* foram (i) a limitação de hardware em capacidade de computação, visto que processadores da época possuíam baixíssima capacidade de processamento e pouca memória; (ii) problemas de “Explosão Combinatória”, problemas que quando dificultados apenas em uma pequena margem resultam em colossal aumento do tempo necessário para sua resolução; (iii) problemas de Qualificação, definidos como a impossibilidade de listar todas as condições pré-existentes necessárias para um computador engajar em ação capaz de resolver problema no mundo real; (iv) problemas de Conhecimentos de Senso-Comum, caracterizados como a incapacidade de codificar em um programa a vasta quantidade de informações minimamente necessárias para resolver ou exercer atividades consideradas simples para humanos, como identificar objetos por meio da visão.

O restante da década de 80 foi marcado por críticas a diversos aspectos das pesquisas conduzidas e seus fundamentos. Hubert Dreyfus argumentara que a razão humana envolvia pouco “processamento consciente de símbolos”, e muito “saber-fazer” instintivo e inconsciente. John Searle, por meio do seu experimento da Sala Chinesa, defendia que um computador jamais seria capaz de esboçar consciência ou de entender o que comunicara, por mais que fizesse perfeito sentido para um interlocutor humano, por não ser capaz de extrair/atribuir sentido aos símbolos – o que ficou conhecido como “intencionalidade”. Contudo, tais críticas não eram tomadas a sério pelos pesquisadores da área e foram ignoradas dada sua irrelevância prática. Problemas de Explosão Combinatória e Conhecimentos de Senso-Comum se revelavam muito mais urgentes e relevantes. Nessa conjuntura, o campo, desacreditado, passou a progredir a passos lentos. - DREYFUS, Hubert; What Computers Can’t Do, 1972; Mind Over Machine, 1986.

²⁵ O *Segundo Inverno* foi ocasionado principalmente pelo (i) colapso inesperado da demanda por hardwares de I.A., dada a forte entrada de computadores pessoais da Apple e IBM no mercado, mais poderosos e baratos; (ii) alto custo de manutenção do equipamento; (iii) dificuldade em desenvolver e implementar novas versões dos softwares; e (iv) incapacidade de lidar com inimigos de longa data, como Problemas de Qualificação.

Nesse período, vários pesquisadores passaram a defender uma nova abordagem para o desenvolvimento de I.A., baseada em robótica, que funcionaria de “baixo para cima”, conhecida como *Nouvelle AI*, ou Nova Inteligência Artificial. Essa linha preceituava que para demonstrar inteligência real, uma máquina necessitava de ter um corpo capaz de interagir com o mundo – de perceber, se mover e sobreviver em um ambiente. Nomes importantes dessa linha rejeitavam abordagens clássicas baseadas em símbolos, defendidas por MCCARTHY e MINSKY. David Marr, por

ocasionados principalmente por promessas ambiciosas - fundadas em avanços inicialmente surpreendentes - que não se aproximaram de concretude dentro dos prazos previstos. As otimistas previsões, revelando-se extremamente exageradas, fizeram com que as instituições responsáveis por fundar as pesquisas retraíssem seu patrocínio e o campo ficasse descreditado. Apesar disso, as décadas que se seguiram, período conhecido como era digital e da informação, trouxeram novidades que possibilitaram forte desenvolvimento da I.A.

Até 2001, avanços lentos e tímidos no campo permitiram que objetivos antigos começassem a ser alcançados²⁶. Essas conquistas, contudo, não foram devidas a descobertas revolucionárias no campo, mas graças aos avanços em tecnologia de processamento computacional e enfoque isolado em problemas específicos²⁷.

A primeira década dos anos 2000 foi inicialmente marcada pela popularização da internet e computadores pessoais, e, posteriormente, de smartphones; o que resultou em uma produção altíssima de dados²⁸ - em proporções jamais vistas. Graças a importantes avanços em hardwares de memória, tais dados se tornaram possíveis de retenção, sendo armazenados em massa em grandes centros de dados. Tal fenômeno possibilitou o eventual nascimento da Big Data²⁹. A época também apresentou surgimento de processadores cada vez mais poderosos³⁰ e novas abordagens em

exemplo, defendia a necessidade prévia de criação de um sistema de visão antes de se adentrar no processamento de símbolos.

²⁶ As conquistas mais marcantes foram desenvolvimento (i) do programa Deep Blue, pela IBM; e de (ii) robô desenvolvido na Universidade de Stanford ganhou pela primeira vez o prêmio DARPA Grand Challenge, ao dirigir autonomamente por 210km de trilha não ensaiada no deserto. Em 1997, Deep Blue surpreendeu o mundo ao vencer Garry Kasparov, se tornando o primeiro a derrotar um campeão mundial de xadrez. Desde o primeiro confronto com Kasparov, em 1996, no qual o supercomputador foi derrotado, sua capacidade de processamento havia dobrado.

²⁷ À época, a reputação da I.A. no mercado permanecia manchada, e a esfera acadêmica permeada de dissensos sobre os motivos que levaram o sonho de se alcançar inteligência de nível humano ao fracasso. Tais fatores levaram a uma fragmentação do campo em sub-áreas focadas em resolver problemas particulares, muitas adotando novos nomes na tentativa de se desvincular da má fama acumulada.

²⁸ Noventa por cento de todos os dados disponíveis hoje foram criados somente nos últimos dois anos (2015 e 2016), correspondendo a quantidade maior que a produzida pela humanidade nos seus últimos 5 mil anos. A expectativa é que quantidade maior seja criada somente no ano de 2017. Em comparação, em 1997, ano em que a internet ganhara ampla popularidade, produzia-se o equivalente a 100GB de informação por hora. Em 2018, estima-se que o número seja de 50.000GB por segundo. Disponível em <http://www.vcloudnews.com/every-day-big-data-statistics-2-5-quintillion-bytes-of-data-created-daily>. Acessado em 15.11.2017.

²⁹ O termo se refere a um conjunto alto de dados acumulados, organizados ou não, complexo e grande o suficiente ao ponto de ser inviável processá-lo por meio de *softwares* convencionais. O termo também está relacionado a sua utilização em análises preditivas e comportamentais, capazes de correlacionar informações e descobrir novos padrões.

³⁰ A Lei de Moore (*Moore's Law*), se originou das observações feitas por Gordon Moore em 1965, que observou, a partir de tendências passadas, que o número de transistores em um circuito integrado tende a dobrar aproximadamente a cada dois anos, ao passo que o custo e o tamanho apenas diminuem. Nesse sentido, caso as tendências persistam, em 50 anos teremos processadores com poder computacional equivalente a de um cérebro humano. Contudo, a Lei de Moore parece encontrar um ponto de quebra. A distância entre transistores está ficando tão pequena ao ponto de não

técnicas de Aprendizado de Máquina (“Machine Learning”, “ML”) – abordado mais a frente; instrumentos que passaram a compor poderoso arsenal a ser explorado pelo campo de I.A.

Munido dessas novas ferramentas e impulsionado por fortes investimentos, o campo passou a apresentar resultados impressionantes³¹, proporcionando confiança para aplicação da tecnologia em novas áreas, cada vez mais complexas. O entendimento de que atividades de capacidade intelectual e criatividade altas estariam imunes à tecnologia começa a ruir, uma vez que pesquisadores já começam a colher frutos na resolução de problemas em áreas além do direito, como economia, linguagem, design.

Hoje, o campo de I.A. floresce como nunca, e não há indicativos de outro inverno em futuro próximo. Pelo contrário, tendo movimentado mais de 8 bilhões de dólares em 2016, o mercado nunca esteve tão forte; e previsões estimam que, até 2020, movimentará mais de U\$ 47 bilhões³².

ii. Entendendo a Tecnologia

Embora o conceito de I.A. seja facilmente delimitado e compreendido como “a capacidade de computadores simularem comportamento de inteligência humana”, nos moldes atuais a tecnologia abarca um conjunto de complexos e distintos conceitos, cuja compreensão é fundamental para adequado entendimento. Em decorrência, serão apresentados, diferenciados e esclarecidos os diferentes elementos que compõem a tecnologia de I.A., evitando eventuais confusões entre os similares termos presentes e aprimorando o entendimento da matéria.

1. I.A. Geral e Restrita

ser possível prosseguir com maior redução sem esbarrar em conflitos a nível atômico, como impossibilidade de manter elétrons em eletrosferas desejáveis. Novas soluções de processamento serão necessárias para que se dê continuidade ao crescimento do poder computacional como indicado.

³¹ Em 2011, o software nomeado de Wattson, desenvolvido pela empresa IBM, venceu os campeões Brad Rutter e Ken Jennings no jogo *Jeopardy!*, que testa conhecimentos gerais dos participantes em diversas áreas por meio de perguntas, atribuindo pontuações proporcionais ao nível de dificuldade das perguntas. Em 2012, *software* desenvolvido pela empresa Google se revelou capaz de identificar gatos em imagens, a partir de treinamentos de observação de vídeos de gatos na plataforma YouTube, se tornando o primeiro programa a apresentar visão computacional de alta precisão.

³² Disponível em <http://www.idc.com/getdoc.jsp?containerId=prUS41878616>. Acessado em 20/10/2017.

O principal propósito, objetivo e grande sonho de muitos que se dedicam ao campo é o desenvolvimento de *verdadeira* I.A., isto é, criar uma máquina capaz de executar com sucesso qualquer tarefa intelectual possível por um humano, simulando sua gama completa de habilidades cognitivas e apresentando, ultimamente, consciência. A esta tecnologia dá-se o nome de *I.A. de Propósito Geral, Completa* ou *Forte* (do inglês, *Strong A.I.*³³, ou *Artificial General Intelligence - AGI*), e consiste na meta mais distante imaginável no momento; verdadeira linha de chegada. Tal tecnologia seria capaz identificar, analisar e solucionar qualquer problema de dificuldade humana sem a necessidade de qualquer interferência, se utilizando tão somente de processos internos do início ao fim³⁴.

Apesar de persistirem controvérsias a respeito do que caracterizaria uma I.A. como de Propósito Geral, existe consenso no que se refere a características como a capacidade de aprendizado / adaptatividade, planejamento, representação de conhecimento, razão estratégica, comunicação em linguagem natural e integração dessas em prol da resolução de objetivos comuns.

Atributos em disputa envolvem as capacidades de *sentir* – reconhecer e trabalhar inputs diversos do ambiente, como luz e sons, captados por meio de sensores especializados –, de *interagir* com o ambiente - se locomovendo ou manipulando objetos³⁵-, de *imaginar* – formulando modelos mentais não pré-programados – e presença de *autonomia* – agir sem intervenção humana ou de outros sistemas. Embora já existam sistemas que apresentem algumas dessas características, não o fazem próximos a níveis humanos.

Conforme salientado no histórico, em meio ao otimismo dos anos 50, pesquisadores estavam convencidos de que *I.A. de Propósito Geral* seria palpável em aproximadas duas décadas. Contudo, os inúmeros anos dedicados a pesquisa promoveram irrisório avanço a empreitada, ficando claro no início dos anos 70 que haviam subestimado a dificuldade do projeto. Em razão do colossal desafio que se revelara, muitos consideraram que nunca seria possível criar máquina capaz de simular a função cognitiva humana. A complexidade da tecnologia é tal que mesmo em face dos

³³ KURZWEIL, Ray. *The Singularity is Near*, Viking Press, 2005, p. 260

³⁴ GOERTZEL B.; PENNACHIN C. *Artificial general intelligence*. Springer, 2007, vol. 2, livro teórico sobre AGI e sua viabilidade no contexto atual. Essa obra também discorre sobre comparativos com ANI e sua área. Vide: SALECHA M. *Artificial narrow intelligence vs artificial general intelligence*, op. cit.

³⁵ PFEIFER, R. and BONGARD J. C. *How the body shapes the way we think: a new view of intelligence* (The MIT Press, 2007).

modernos avanços não se imagina que seja alcançada em futuro próximo. Hoje poucos pesquisadores são ativos na área; projetos são diversos e geralmente pioneiros em natureza.

Os resultados insatisfatórios fizeram que, ao final da década de 70, pesquisadores abandonassem o objetivo e passassem a adotar abordagem distinta, voltada à resolução de problemas específicos. Passaram então a se voltar ao desenvolvimento de Sistemas Especialistas³⁶, primeiros integrantes da *I.A. de Propósito Específico, Limitada ou Fraca* (do inglês, *Artificial Narrow Intelligence, ou ANI*). Essa, diferente da *AGI*, se utiliza de softwares para atacar problemas particulares dentro de áreas específicas e bem delimitadas. Reduzindo em muito o escopo do problema e dividindo-o em tarefas isoladas, essa abordagem possibilitou a obtenção de melhores respostas aos desafios propostos, se tornando a primeira forma da tecnologia a apresentar resultados satisfatórios e considerada um sucesso. Hoje programas de *ANI* já são utilizados em diversas tarefas, como direção automática de carros, traduções livres em tempo real³⁷ e competição em jogos digitais.

Um bom exemplo para se compreender a extensão do potencial de programas de *I.A. Restrita* e ilustrar suas principais diferenças em relação à *I.A. Geral* são assistentes de voz modernos, como a Siri da Apple. Se utilizando de conexão à internet para acesso a vasta base de dados, Siri aparenta deter inteligência, sendo capaz de manter diálogos simples com fluidez e tato, incluindo comentários perspicazes, sarcasmos e piadas. Apesar das aparências, esses programas não se aproximam de uma *I.A. Geral*, pois não possuem capacidade real de raciocinar, resolver problemas ou noção de si; seu escopo é limitado à automatização de ações simples a partir de comandos de voz, como buscas, lembretes, alarmes, respostas a perguntas frequentes / comuns.

Suas restrições são evidenciadas ao se desafiar o programa em tarefas para as quais não foi codificado e treinado para responder. Programas dessa natureza são extremamente “inteligentes”

³⁶ Sistemas Especialistas são programas que capazes de resolver problemas em áreas específicas ao simularem o processo de tomada de decisões de humanos especialistas no campo. Seu funcionamento é baseado em dois elementos: uma base de dados, geralmente desenvolvida e curada por especialistas da área objeto, e uma ferramenta de inferência, que aplica regras programadas aos fatos detidos em sua base para deduzir novos fatos. Tais sistemas foram os primeiros a apresentarem resultados satisfatórios em predição e análise de riscos, diagnósticos médicos, planejamento, monitoramento, etc.

³⁷ Em outubro desse ano a Google anunciou par de fones de ouvido com tecnologia de *I.A. Restrita*. Possuindo captador de som, o fone é capaz de reconhecer frases em diversos idiomas e traduzi-los rapidamente, dentro de 2 a 3 segundos, para uma das 40 linguagens em seu arsenal. Apesar de tecnologia de tradução utilizada já existir a alguns anos, os fones exemplificam como a *I.A.* está se tornando cada vez mais acessível, barata e presente no nosso cotidiano. Barreiras linguísticas antes intransponíveis para alguns hoje são derrubadas facilmente graças ao poder da *I.A.*

no que se propõe a fazer, atuando com precisão, eficiência e rapidez desumanas em sua área; contudo, a extensão de sua inteligência é a das tarefas pré-determinadas pelo programador, sendo incapazes de fornecer resultados eficazes em problemas que ultrapassam sua configuração inicial, ou sequer reconhece-los.

2. Machine Learning e Redes Neurais

A evolução do potencial de resolução de problemas por Programas de *I.A. Restrita* se deu como reflexo de estudos recentes em abordagens de engenharia computacional, que vem apresentando, a ritmo acelerado, resultados que se julgavam longe de concretização. O ano de 2017 fora marcado por conquistas notáveis. Diversas publicações e experimentos de sucesso foram conduzidos em tarefas complexas, como razão relacional³⁸, transferência de estilo semântico³⁹ e planejamento com base em imaginação⁴⁰.

Área em que a tecnologia recentemente apresentou resultados notáveis foi a de jogos. Em maio, o programa AlphaGo, desenvolvido pela Google Deep Mind, vencera campeão mundial⁴¹ no antigo jogo chinês de tabuleiro *go*. Em novembro, nova versão do programa, nominada de AlphaGo Zero⁴², fora capaz de dominar AlphaGo em uma série de 100 jogos consecutivos.

³⁸ Razão Relacional é um componente central de comportamento inteligente, e tem se revelado com um problema difícil de aprendizado por redes neurais. No estudo, os algoritmos desenvolvidos foram capazes de identificar objetos bi e tridimensionais distintos em imagens, fornecendo respostas para perguntas relacionais simples, como qual objeto se encontrava mais próximo/longe de outro, sua forma e sua cor. A capacidade apresentada pelo algoritmo está muito à frente das soluções propostas até o momento, inclusive apresentando resultados sobre-humanos em diversas ocasiões. SANTORO, Adam. A simple neural network module for relational reasoning, 2017. Disponível em <https://arxiv.org/abs/1706.01427>. Acessado em 25.11.2017.

³⁹ Caracterizada como a capacidade de aplicar o estilo estético de uma imagem a outra imagem, adaptando-a ao estilo desejado. Por exemplo, pode-se fornecer a foto de um cachorro (A) e um quadro impressionista (B). O algoritmo é capaz de compreender o estilo impressionista de B e aplica-lo à A, produzindo um cachorro impressionista. A maior conquista do projeto foi a de reconhecer semanticamente os objetos da imagem, i.e., casas ou árvores, e traduzi-los com o estilo desejado. LIAO, Jing; YAO, Yuan. Visual Attribute Transfer through Deep Image Analogy, 2017. Disponível em <https://arxiv.org/pdf/1705.01088.pdf>. Acessado em 25.11.2017.

⁴⁰ Essa abordagem de solução foi utilizada em jogos virtuais para solucionar dificuldades de planejamento a longo prazo, sendo capaz de não só adotar ações individuais, mas planos complexos envolvendo diversos passos, escolhendo aquele que oferece a maior recompensa esperada. WEBER, Théophane. Imagination-Augmented Agents for Deep Reinforcement Learning, 2017. Disponível em <https://arxiv.org/abs/1707.06203>. Acessado em 26.11.2017.

⁴¹ O Sul Coreano Lee Sedol é tido como o melhor jogador de *go* de todos os tempos, e atualmente ocupa a segunda posição em títulos internacionais. Fora vencido pelo pelo programa AlphaGo em uma série de 1-4 partidas.

⁴² A diferença entre ambos os programas se encontra no processo de treinamento das redes. AlphaGO fora previamente treinado observando uma variedade de jogos profissionais de *go*, recebendo uma “educação” inicial sobre o jogo,

Já em agosto, programa desenvolvido pela *startup* americana OpenAI foi pela primeira vez capaz de derrotar jogadores de elite em confrontos individuais no jogo virtual de ação e estratégia em tempo real (RTS), surpreendendo a comunidade e o mundo⁴³. Seu fundador comentou em publicação que a complexidade do *e-sport* é vastamente superior a de jogos de tabuleiro como *go* e xadrez, colocando em perspectiva o rápido avanço da tecnologia.

O mérito das conquistas é evidenciado ao denotar-se o nível de complexidade atinente a tais jogos. O antigo jogo chinês *go* até então se revelava como o mais intrincado a ser dominado por uma I.A., possuindo número virtual de partidas distintas na ordem de 10^{1761} ; vastamente superior ao xadrez (10^{120}) e ao número de átomos existentes no universo (10^{80})^{44,45}.

passando por combinação de aprendizado supervisionado e reforçado. Já AlphaGO Zero recebera tão somente treinamento reforçado. Tendo somente pixels como input inicial, a rede fora colocada para jogar contra si sem conhecimento prévio nenhum sobre o jogo, partindo do zero, como o nome sugere. A partir de inúmeras interações com si mesma, e desvinculada de qualquer paradigma humano, a rede fora capaz de aprender sozinha movimentos iniciais clássicos e poderosos, como *Honte* e *Tesuji*, resultado de anos de experiência humana. Em apenas 3 dias de treinamento, Zero atingira o nível de habilidade (quantificado em ELO) da versão do programa que vencera Lee Sedol. Em 21 dias, atingira nível de sua versão Master, que vencera 60 profissionais de elite e campeão mundial de 2017, Ke Jie, em uma série limpa de 3 jogos. Em 41 dias, Zero atingiu o maior ELO da história de *go*, se tornando provavelmente o melhor jogador de *go* da história. HASSABIS, Demis. AlphaGo Zero: Learning from scratch, 2017. Disponível em <https://deepmind.com/blog/alphago-zero-learning-scratch/>. Acessado em 15.11.2017.

⁴³ O feito se refere ao jogo *Dota 2*, e ocorrera como surpresa durante a final do campeonato mundial de 2017, chocando todos que acompanhavam o evento.

⁴⁴ Em *go* e no xadrez, tais números de são determinados por dois fatores: (i) o número de jogadas possíveis a cada estado de tabuleiro – 35 no xadrez, de tabuleiro 8 x 8; contra 250 em *go*, de tabuleiro 19 x 19 - e (ii) a duração do jogo – média de 80 movimentos no xadrez contra 150 em *go*. A complexidade de jogos de RTS se revela superior não somente por apresentarem maior variação em (i), como por apresentarem um terceiro fator: (iii) janela temporal de ação, que amplifica em muito o poder computacional necessário. Ou seja, além do planejamento estratégico a longo prazo, há a necessidade de variadas reações extremamente rápidas a cada momento.

Diferente dos jogos de tabuleiro, que correm em turnos alternados em ordem definida, sendo concedido tempo individual para cada jogador realizar sua jogada com calma – e permitindo maior intervalo para processamento; jogos de RTS não possuem divisão entre turnos próprios e do oponente: ambos podem realizar inúmeras ações a todo e qualquer momento. Isso significa que o programa deve ser capaz de emular rápidos truques e blefes na tentativa de enganar o oponente em tempo real. Jogos dessa natureza não só possuem um número superior de opções a serem consideradas e de ações possíveis para um estado de tabuleiro, como essas devem ser processadas, avaliadas e executadas instantaneamente, sob o risco de o estado do tabuleiro se alterar e o movimento perder seu valor inicial em caso de atraso – exigindo, por sua vez, maior poder computacional.

Impressionante é que algoritmo utilizado não recebera nenhuma instrução inicial, seja as regras do jogo ou as ações possíveis. Fora programado tão somente para “vencer”, descobrindo sozinho como fazê-lo da melhor maneira possível, diferente do programa AlphaGo, que recebera base de dados contendo inúmeros jogos profissionais de *go* como suporte inicial de aprendizado. Além disso, o algoritmo fora treinado por somente 24 horas - tempo extremamente curto em comparação a demais algoritmos – jogando somente contra si mesmo.

⁴⁵ Para entender como esses programas são capazes de superar os melhores candidatos humanos nesses jogos, utiliza-se do conceito de Árvore de Estados, que, em jogos, representa o número de estados de tabuleiro possíveis. A origem da Árvore representa o estado inicial do jogo, da qual se desdobram outros possíveis estados de tabuleiro - limitados pelas ações passíveis de serem tomadas nas respectivas situações de origem.

Para problemas simples, como jogo da velha ou damas, o número de desdobramentos possíveis é reduzido e passivo de representação sem dificuldade, permitindo que um programa avalie e escolha, dentre todas as alternativas, a melhor

Em razão dos absurdos valores envolvidos, não é possível, com a tecnologia de hardware disponível atualmente, processar tantos estados de tabuleiro em tempo hábil se utilizando somente de poder computacional bruto. É nesse ponto que os recentes avanços em Machine Learning e Redes Neurais, subcampos de I.A., têm se destacado. Essas abordagens são capazes de extrair extraordinários resultados se utilizando do mesmo poder computacional disponível.

Machine Learning é caracterizado como estudo e desenvolvimento de algoritmos capazes de aprender e fazer previsões a partir de dados⁴⁶, superando programações estritas e limitadas a escopos iniciais e concedendo a computadores a capacidade de “aprender sem serem expressamente programados⁴⁷”. São aplicados em tarefas computacionais nas quais a programação de algoritmos específicos se revela difícil ou inviável, como visão computacional e tradução de textos.

Em Machine Learning, são utilizadas três abordagens básicas: as de aprendizado (i) supervisionado, (ii) reforçado, e (iii) não-supervisionado⁴⁸ - de aplicação mais restrita. Cada abordagem é voltada a resolução de problemas distintos.

No Aprendizado Supervisionado, usado para tarefas de classificação e regressões, obtêm-se inteligência a partir de conhecimentos pré-determinados. Sua função básica é a de categorizar elementos em classes pré-definidas; por exemplo, identificar se o conteúdo de uma imagem corresponde ou não a classe “gato”, ou se um ato processual corresponde a classe “sentença”, “despacho”, etc.

disponível. Já para jogos da magnitude de xadrez ou *go*, essa tarefa se torna inviável – visto que a Árvore de Estados teria quantidade de nós impossível de ser armazenada em computador, sequer processada.

Em razão de tal complexidade, foi adotada diferente abordagem pelo programa Deep Blue, que venceu o campeão mundial de xadrez Garry Kasparov em 1997. Não sendo possível acessar a completa gama de possibilidades da Árvore de Estados no xadrez, o programa analisava os desdobramentos da Árvore até a máxima profundidade possível – algo em torno de 6 a 7 movimentos do estado atual. Então, era utilizada uma função que avaliava a qualidade desses desdobramentos e atribuía um valor singular para cada um. Ao final, o programa optava pela de maior valor. Quanto mais próximo do fim do jogo, melhor era a avaliação feita pela função, em razão do número reduzido de jogadas possíveis. O método utilizado para atacar o problema se utiliza de funções heurísticas e poder de processamento bruto, esbarrando em limitações de hardware.

⁴⁶ KOHAVI, Ron; PROVOST, Foster. Glossary of terms - Machine Learning, 1998, pgs. 271–274.

⁴⁷ KOZA, John R.; BENNETT, Forrest H.; ANDRE, David; KEANE, Martin A. Automated Design of Both the Topology and Sizing of Analog Electrical Circuits Using Genetic Programming. Artificial Intelligence in Design, 1996, pgs. 151–170.

⁴⁸ Difere dos demais por não objetivar prever certos resultados a partir de conhecimento correlacional prévio e determinado entre *inputs* e *outputs* - aqui, sequer se sabe que tipo de resultado será obtido. Trata-se de um método voltado a organizar e extrair novas informações de uma população de dados a partir de extensa comparação de suas características. Os algoritmos utilizados são capazes de explorar e identificar padrões ocultos nos dados, agrupando-os conforme semelhanças e divergências observadas. Algoritmos popularmente utilizados são os de mistura gaussiana, k-vizinhos, agrupamento hierárquico, mapas auto-organizáveis e modelos *hidden matov*.

Recebe essa nomenclatura por ser análogo a um professor conduzindo um processo de ensino, em que esse, previamente sabendo a resposta certa (*output* desejado) para uma pergunta apresentada (*inputs*), treina o aluno até que seja capaz de, por si só, responder novas perguntas corretamente com determinado grau de acerto / precisão.

Esses algoritmos são treinados a partir da exposição a uma vasta quantidade de dados organizados, chamados de *exemplos de treinamento*. Ao identificar, analisar e correlacionar diferentes características dos *exemplos* apresentados, o algoritmo é capaz de criar, após inúmeras interações, um mapeamento linear entre *exemplos* e *respostas* corretas – isto é, *classes* previamente conhecidas e delimitadas. O objetivo é que o algoritmo se torne capaz de generalização - compreender e correlacionar tão bem a estrutura e características dos *inputs*, ao ponto de fornecer, com elevado grau de precisão, *outputs* corretos para *inputs* novos / desconhecidos, pelos quais não foi treinado.

Já o Aprendizado Reforçado é utilizado na resolução de problemas com várias etapas e que envolvem tomadas de decisões em sequência - como jogos ou direção de veículos. Seu nome e funcionamento são inspirados na psicologia behaviorista, em que se treina um agente a apresentar um determinado comportamento a partir de *reforços* positivos ou negativos (*feedback*).

Nessa abordagem, o algoritmo é considerado um *agente*, inserido em um *estado*, no qual realiza, dentre leque delimitado de possibilidades, uma *ação*, que, por sua vez, o transfere a um novo *estado*, e assim em diante⁴⁹. Trabalha-se com a noção de tempo e estratégia a longo prazo, em que cada ação realizada limita e influencia opções e decisões futuras. O objetivo é que o agente se torne capaz de tomar decisões que maximizem resultados positivos.

Dessa maneira, não visa criar um classificador, capaz de categorizar exemplos (*inputs*) em classes (*outputs*) pré-definidas. Aqui, em verdade, sequer existe noção prévia de *output* certo ou errado – a ideia é que o algoritmo interaja livremente com o ambiente e descubra por si só, a partir de *feedbacks*, o melhor *output* que conseguir. O supervisor, no caso, não sabe de antemão qual o *output* correto para os *inputs* que fornece, mas sabe informar para o algoritmo, ao final, se gostou ou não de sua decisão, se foi boa ou ruim, melhor ou pior que decisões anteriores.

⁴⁹ BARTO, A., POWELL, W., WUNSCH, D. Reinforcement Learning and Its Relationship to Supervised Learning, in Handbook of Learning and Approximate Dynamic Programming, John Wiley & Sons, Inc., Hoboken, 2004.

Essa abordagem utiliza-se de programação mais ampla, genérica e principiológica, na qual são delimitadas **(i) ações** - escolhas passíveis de serem tomadas pela máquina dentro do contexto em que está inserida – i.e., movimentos em um jogo ou em condições reais, como acelerar, frear ou virar um veículo; e **(ii) critérios de sucesso**, que definem a natureza do *feedback* / recompensas – i.e., vitória ou maior pontuação em jogos; ou a não colisão do veículo.

Por sua vez, o treinamento desses algoritmos não consiste na exposição a dados organizados, mas à submissão a diversas situações teste, nas quais é livre para realizar diversas *ações* e receber, ao final, um *feedback* – positivo ou negativo. Inicialmente, o algoritmo não sabe qual a melhor *ação* a ser tomada em um *estado*, sendo necessário que realize, literalmente, um chute. Com base na noção de recompensa cumulativa pré-estabelecida, algoritmo memoriza o *feedback* obtido para cada predição, série de ações e resultado final, e passa a pautar suas ações futuras com base no quão “boas” foram suas decisões passadas em determinados contextos / situações.

Existem diferentes algoritmos para as abordagens de Machine Learning apresentadas acima, com vantagens e desvantagens a depender do problema a ser atacado. Dentre esses, dá-se especial enfoque ao de Redes Neurais, importante pilar do desenvolvimento moderno de I.A., responsável por importantes avanços e surpreendentes resultados no campo.

Redes Neurais consistem em uma família de modelos de Machine Learning baseada na estrutura neural biológica observada no cérebro humano. O modelo está compreendido na abordagem *conexionista* de estudos de I.A.⁵⁰, iniciada na década de 40⁵¹. Apesar de ser hoje o arquétipo mais adotado no campo, não recebera devida atenção até o início dos anos 80.

Durante o período de sua proposição inicial, vários fatores contribuíram para sua baixa adoção e desinteresse, principalmente **(i)** a forte oposição por estudiosos da linha *simbólica*, cujos adeptos defendiam que a mente humana funcionava por meio do processamento sequencial simples de operações formais de símbolos, como uma Máquina de Turing; **(ii)** a limitação tecnológica da época e **(iii)** reduzido conhecimento biológico a respeito da estrutura e funcionamento do cérebro. Os últimos impossibilitavam desenvolvimento de projetos práticos capazes de produzir resultados

⁵⁰ Também abrange campos da psicologia cognitiva, neurociência e filosofia da mente.

⁵¹ ELMAN, Jeffrey L. Rethinking Innateness: A Connectionist Perspective on Development (Neural Network Modeling and Connectionism), 1996.

relevantes, verificações de hipóteses e maiores aprofundamentos. Com o passar das décadas essas barreiras foram se vendo superadas, o que permitiu o florescimento da abordagem.

Atualmente, sabe-se que o cérebro contém milhões de neurônios maciçamente interligados em paralelo - e não serialmente, como sugerido pela linha *simbólica* – realizando vários processos simultaneamente. Cada neurônio é composto por um núcleo e dois filamentos distintos, responsáveis pela formação da rede neural: os axônios, responsáveis pelo envio de impulsos elétricos; e os dendritos, responsáveis por captá-los.




Fig. 2 – Estrutura de Neurônio – Fonte: (<https://www.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/overview-of-neuron-structure-and-function>)

Visto que o propósito da abordagem *conexionista* era o de criar modelo sintético que simulasse o funcionamento do cérebro humano, redes neurais artificiais foram desenvolvidas de forma a apresentar contrapartes análogas às estruturas biológicas. São constituídas por um conjunto de unidades simples (também chamadas de “neurônios”) interconectadas em complexa rede – de forma variável a depender da arquitetura utilizada.

Os neurônios artificiais consistem em funções matemáticas capazes de receber, processar e transmitir valores/sinais adiante na cadeia neural (HAYKIN, 1994)⁵². Cada neurônio é designado ao processamento de características individuais bem delimitadas de um problema, e ao trabalharem em conjunto, são capazes de produzir resultados complexos. O primeiro tipo de neurônio artificial proposto foram os *perceptrons*⁵³, responsáveis por introduzir o essencial conceito de *peso*, trabalhado abaixo. Hoje o modelo de neurônio mais utilizado é o do tipo *sigmoid*⁵⁴, que oferece maior flexibilidade.

O *peso* consiste em um valor numérico atribuído a cada conexão entre dois neurônios, e é responsável por definir a relevância / força dos sinais que uma unidade neural emite a outra. Quanto maior o *peso* atribuído a uma conexão, mais forte será o impulso emitido e sua relevância no cálculo do *output* resultante. Na imagem abaixo, são representados os neurônios (x_1, x_2, x_3, x_n), seus respectivos pesos (w_1, w_2, w_3, w_n), o *valor limite* θ , e soma ponderada resultante Σ .




Fig. 3 - Estrutura de um Perceptron. Fonte: (<https://github.com/cdipaolo/goml/tree/master/perceptron>)

⁵² POERSCH, José. Simulações Conexistas: A inteligência artificial moderna, 2004. Disponível em <http://linguagem.unisul.br/paginas/ensino/pos/linguagem/linguagem-em-discurso/0402/040209.pdf>. Acessado em 26.10.2017.

⁵³ Desenvolvidos na década 50 e 60 por Frank Rosenblatt, inspirado no trabalho de Warren McCulloch e Walter Pitts. *Perceptrons* podem ser resumidos como mecanismos simples de tomada de decisões a partir da comparação de evidências numéricas. Esse modelo recebe n inputs binários, multiplica-os pelo *peso* atribuído a cada conexão e realiza uma soma ponderada de todos para produzir um único sinal resultante, também binário. O valor do output – 0 ou 1 – depende de se a soma ultrapassa ou não *valor limite* previamente estabelecido (*threshold value*). Em caso positivo (1), o neurônio é “ativado” e propaga seu sinal na rede; em caso negativo (0) o neurônio permanece inerte e não envia sinal adiante. – ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological review*, 1958, pg. 386.

⁵⁴ Sua grande diferença em relação aos *perceptrons* é que seu valor de output não é binário, podendo variar entre qualquer valor entre 0 e 1. A consequência disso é que se torna possível controlar melhor a influência que os *pesos* e *valores limites* terão sobre o *output* do neurônio; de forma que, por exemplo, pequenas alterações nos pesos da rede não resultem em largas e desproporcionais alterações nos outputs, permitindo mais flexibilidade e melhor afinação no aprendizado.

As redes artificiais são estruturadas em três camadas básicas: **(i)** camada de entrada (*input layer*), que recebem estímulos externos à rede, **(ii)** camada de saída (*output layer*), que transmitem estímulos para fora da rede, e **(iii)** camada(s) intermediária(s) ou oculta(s) (*hidden layers*), responsável pelo processo de aprendizagem da rede e comunicação entre as demais⁵⁵. As camadas podem possuir número variável de neurônios, a depender da arquitetura adotada para o modelo⁵⁶.




Fig. 4 – Estrutura de Rede Neural Artificial. Fonte: (<http://neuralnetworksanddeeplearning.com/chap1.html>)

Existem diferentes tipos de Redes Neurais; suas características distintas permitem que ataquem problemas específicos com maior eficiência que os demais.

Redes Neurais Pró-Alimentadas (Feedforward Neural Network – FNN) compreendem o primeiro e mais simples tipo de rede artificial desenvolvida. Sua arquitetura comporta múltiplas

⁵⁵ Geralmente, a estruturação das camadas de entrada e saída tendem a ser intuitivas; são as camadas intermediárias que se revelam complexas de desenhar. Pesquisadores vêm desenvolvendo diferentes projetos e modelos para camadas intermediárias, visando facilitar a obtenção dos resultados almejados das redes. Esse modelos podem, por exemplo, realizar avaliação de custo benefício entre número de neurônios e camadas em relação ao tempo necessário para o treinamento da rede. <http://neuralnetworksanddeeplearning.com/chap1.html>

⁵⁶ Projeto inovador chamado AdaNet (*Adaptive Structural Learning of Artificial Neural Networks*) é um Sistema de Machine Learning voltado ao design de arquitetura de redes. Ao receber largo conjunto de dados estruturados, é capaz de construir uma rede neural, camada por camada, testando e adicionando novos elementos à estrutura de maneira eficiente, buscando sempre o melhor desempenho. As redes desenhadas pelo programa têm conquistado resultados melhores do que redes tradicionais desenvolvidas à mão, que chegam a ser duas vezes maior. <http://www.cs.nyu.edu/~mohri/pub/adanet.pdf>

camadas pró-alimentadas - seus neurônios não apresentam ciclos e não se comunicam com unidades de camadas anteriores, transmitindo sinais somente “para frente”. Dentre suas variáveis, encontram-se as Redes Convolucionadas (CNN)⁵⁷.

Redes Neurais Recorrentes (Recurrent Neural Networks – RNN-LSTM), por sua vez, não só propagam dados para frente, como também para trás – neurônios de camadas mais profundas se comunicam com os de camadas mais superficiais e com si mesmos, formando ciclos e apresentando uma “memória”. Essa interconexão regressiva permite que combinem informações instantâneas a informações previamente processadas à presente tarefa, situando-a em um contexto e facilitando sua resolução⁵⁸.

Como salientado, a característica mais especial de redes *conexionistas* é a sua propensão à aprendizagem. Sistemas de Rede Neural são capazes de progressivamente melhorar sua performance em determinada tarefa a partir da consideração de exemplos, armazenando conhecimento experiencial e tornando-o utilizável (HAYKIN, 1994). Para tal, são submetidos a processos de aprendizado, nos modelos de Machine Learning apresentados anteriormente. Como mencionado, o conhecimento experiencial é obtido por meio da análise de dados organizados (supervisionado) ou a partir de interações livres com o meio guiadas por *feedbacks* (reforçado).

O aprendizado das redes ocorre a partir da utilização de *algoritmos de treinamento*⁵⁹. Esses têm a especial função de reorganizar a distribuição de *pesos* na rede neural a partir de cada experiência / interação com o ambiente, buscando sempre otimizar seu nível sucesso, i.e., a maior recompensa em uma tarefa ou a correta classificação de um objeto.

⁵⁷ Essas possuam estrutura inspirada na organização biológica do córtex visual animal, e são especialmente bem adaptadas ao reconhecimento e categorização de imagens e vídeos. Cada camada da rede aplica um filtro distinto à imagem, que identifica características básicas (formato, cor, arestas, curvas, etc.) e, a partir delas, escalonam para aspectos mais complexos e abstratos.

⁵⁸ As informações “antigas” / pré-processadas são extremamente voláteis, se perdendo facilmente ou se tornando difíceis de acessar quanto maior a distância entre os neurônios envolvidos. Com intuito de aumentar a resiliência de informações dentro da rede neural, foi desenvolvido o conceito de Memórias de Longa/Curto Prazo (Long Short Term Memories – LSTM). Essa abordagem incorpora células de memória nos neurônios intermediários, capazes de armazenar, esquecer e propagar informações a partir de portas (*gates*) especializadas. Ao permitir que informações perdurassem por mais tempo na memória, condeu a RNNs a capacidade de acessar informações “distantes” em sua rede e fazer correlações de médio-longo prazo. HOCHREITER, S; SCHMIDHUBER, J. Long short-term memory, Neural computation, 1997, pgs. 1735-1780.

⁵⁹ Os algoritmos de treinamento buscam e identificam no espaço de soluções a função correspondente ao menor custo possível. Os mais utilizados são os de gradiente descendente, propagação reversa, gradiente conjugado, mínimos quadrados, aprendizado competitivo, método de Newton e Quase-Newton.

O processo de aprendizado consiste, dessa maneira, em um ajuste contínuo dos *pesos* atribuídos às conexões neurais, no qual o algoritmo reforça as que levam a resultados positivos, aumentando seu *peso*, e, inversamente, enfraquece as que levam ao fracasso. A partir de múltiplas tentativas e erros, o algoritmo vai desvendando e consolidando a configuração que resulta no maior nível de sucesso. Durante o treinamento - que pode levar semanas a meses a depender do projeto - são testadas e comparadas inúmeras configurações distintas.

Ao alterarem os *pesos*, os algoritmos moldam e codificam a rede neural a partir das informações adquiridas pela camada de entrada⁶⁰. Assim como no cérebro, a *memória* da rede neural artificial, obtida com o aprendizado, é definida pela qualidade das ativações que atingem cada um dos neurônios que a compõem; ou seja, pelo conjunto geral de *pesos* atribuídos a cada conexão.

Diz-se que aprendizado chega ao fim quando a rede apresenta índice de desempenho considerado satisfatório. O aprendizado, contudo, nunca deve se encerrar de fato. Isso por que os *inputs* recebidos são determinados por condições do ambiente, externas ao sistema. Caso o aprendizado seja encerrado, eventual mudança drástica nos *inputs* recebidos resultaria em resultados imprecisos e na inutilidade do programa. Por essa razão, é importante que, mesmo após disponibilizados para utilização prática, o processo de aprendizado continue em vigor, permitindo que os programas constantemente se adaptem e se atualizem a novidades, buscando manter seu nível de desempenho.

iii. Aplicações Gerais

Como mencionado, a aplicação de I.A. se estende a diversos campos e atividades. Atualmente, dentre as aplicações mais atraem investimentos estão as de (i) automação de serviços de atendimento a consumidores; (ii) algoritmos de predição e recomendação de interesses - aplicados a notícias, vendas, comportamentos, locais, filmes, músicas, temperatura, etc.⁶¹; (iii) sistemas de diagnóstico e tratamentos médicos, (iv) investigação e análise de fraudes, (v) assistentes pessoais - capazes de reconhecer a fala humana e auxiliar com agendamento de tarefas,

⁶⁰ Ressalta-se que a arquitetura adotada também influencia diretamente na eficiência do processo.

⁶¹ São sistemas que filtram fragmentos de informações relevantes dentro de um grande conjunto de dados gerados dinamicamente por usuários, como suas preferências, interesses e padrões de comportamento; também são capazes de prever comportamentos e interesses futuros a partir da análise do perfil de usuários e comparação com as informações acumuladas.

requisição de serviços, comunicação interpessoal, por telefonia ou e-mail, tirar dúvidas, etc.⁶²; e (vi) direção automatizada de veículos.

Os benefícios econômicos trazidos pela ampliação e integração da tecnologia vão muito além da redução de custo proveniente da substituição da mão de obra humana envolvida. Será possível diminuir custos gerais de supervisão de cadeias produtivas, atingir maiores escalas de produção e, ao eliminar erros humanos intrínsecos, assegurar maior qualidade e segurança aos serviços e produtos disponibilizados ao mercado.

iv. Aplicações no Direito

No que diz respeito à sua aplicação ao Direito, várias iniciativas já se utilizam da tecnologia para proporcionar soluções em diferentes atividades. Contudo, por se tratar da primeira fase de desenvolvimento e experimentação, esbarram em limitações horizontais e verticais – no que se refere a áreas de atuação legal e funções passíveis de execução, respectivamente.

Dessa maneira, atividades tidas como mais complexas, caracterizadas como as requerem alto grau de empatia, criatividade, sensibilidade, ou simplesmente interação física com o meio, estão mais distantes de serem emuladas por computadores, e não se revelam ameaçadas pela tecnologia em futuro próximo. Dentre essas, podem ser citadas a comunicação e negociação entre partes; o comparecimento a juízo e aconselhamento de clientes.

No momento, as funções as quais a tecnologia alcança são as consideradas mais “simples” dentro do ramo. Dessas, destacam-se as de (i) pesquisa jurídica, consistindo em buscas avançadas de jurisprudência, legislação, regulações, etc.; (ii) revisão contratual, capazes de identificar a presença ou ausência de determinadas cláusulas contratuais e implementar cláusulas comuns /

⁶² Tais sistemas permitem que computadores respondam diretamente a uma ampla gama de solicitações humanas, Por exemplo, o Siri da Apple e o Now da Google se utilizam de interfaces de usuário naturais para reconhecer as palavras faladas, interpretar seus significados e agir em conformidade. Uma empresa chamada SmartAction já utiliza tecnologia de Machine Learning e reconhecimento avançado de voz para fornecer soluções em informatização de chamadas de voz para melhorar sistemas convencionais de resposta de voz interativa. A utilização dessa tecnologia é responsável pela redução de 60 a 80% dos custos de um centro de atendimento terceirizado nos Estados Unidos. (CAA, 2012). FREY, Carl; OSBORNE, Michael. The future of employment: how susceptible are jobs to computerization, 2013. Disponível em http://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf. Acessado em 15.10.2017.

standard; e (iii) sugestão de estratégias, a partir da mineração de informações relevantes por meio de análise e correlação de uma alta quantidade de dados, identificando tendências e padrões úteis.

Essas aplicações trazem diversos benefícios estruturais e econômicos tanto para usuários individuais como para empresas. O atual e crescente oceano de informações jurídicas excede as capacidades humanas de memória, pesquisa e análise. O auxílio artificial permitirá a seus operadores que o naveguem com maior praticidade, rapidez e eficiência. Já empresas passam a agregar o potencial “artificial” à sua cadeia de produção ou prestação de serviços, permitindo que ultrapassem os presentes limites biológicos e expandam sua atuação para níveis sobre-humanos, ao delegar à máquina cargas de trabalho e funções as quais humanos não estão aptos ou dispostos a arcar e executar. Todos esses benefícios reduzem custos e tempo investidos, que se traduzem, por sua vez, em serviços mais baratos, rápidos e de maior qualidade.

Mesmo que ainda não sejam capazes de realizar a totalidade de tarefas autonomamente, é incontestável que se apresentam como grandes ferramentas para assistir e facilitar o trabalho de seus usuários. Colocando em perspectiva, usuários da tecnologia reportam, para revisões contratuais, uma redução de 20 a 60% do tempo médio necessário para completude da tarefa. Já um sócio de escritório de advocacia localizado em Miami, no início cético, ficou surpreso ao verificar que uma pesquisa jurídica que havia lhe tomado em torno de 10 horas fora realizada em segundos pelo *software* especializado ROSS⁶³ - trabalhado em detalhes mais abaixo. O mesmo programa é responsável por reduzir o tempo gasto em até 70% em pesquisas jurídicas e 30% em redações.

Números positivos como esses inevitavelmente atraem atenção e investimentos, possuindo forte potencial para incremento da eficiência da justiça. Para se entender melhor o funcionamento da tecnologia, abaixo serão apresentados e analisados os principais programas que vem sendo utilizados por profissionais de diferentes áreas do direito, seu funcionamento e aplicações.

1. ROSS

⁶³ New York Times - A.I. Is Doing Legal Work. But It Won't Replace Lawyers, Yet. Disponível em <https://www.nytimes.com/2017/03/19/technology/lawyers-artificial-intelligence.html>. Acessado em 8.10.2017

A IBM, desenvolvedora americana de softwares e hardwares – responsável pelo desenvolvimento do ROSS, é notória gigante da computação e se encontra entre as 50 empresas mais valiosas do mundo. Fundada em 1911, hoje atua em mais de 170 países, emprega funcionários de altíssimo nível, incluindo ganhadores de Prêmios Nobel, e está entre as líderes mundiais no desenvolvimento de tecnologias de I.A.

Seu projeto Watson, iniciado no final de 2005, é um sistema computacional capaz de compreender e responder perguntas em linguagem natural. Foi criado com intuito de competir no programa *Jeopardy!*, famoso jogo de conhecimentos gerais televisionado nos Estados Unidos, sendo capaz de vencer os antigos campeões do show em 2011. O objetivo do programa era, segundo um de seus desenvolvedores, o de “*fazer com que computadores comecem a interagir por meio de linguagem natural humana em uma gama de aplicações e processos, recebendo perguntas feitas por humanos e provendo respostas que possam ser por compreendidas e justificadas*”⁶⁴.

O novo projeto da empresa, **ROSS**, é uma plataforma de I.A. que combina as tecnologias de computação cognitiva e de processamento de linguagem natural do Watson com os recentes avanços em *Machine Learning* para identificar e apresentar materiais legais relevantes para perguntas jurídicas particulares, i.e., um grande e aprimorado sistema de buscas. Seu diferencial está no fato de seus usuários não precisarem escrever termos de busca complexos e organizados: basta que seja feita pergunta simples em linguagem natural. A capacidade de análise semântica do ROSS o permite que compreenda a “intenção” da pergunta e identifique respostas no limite da matéria tratada e adequadas ao contexto, destacando-se de sistema de buscas convencionais, além de fornecer resultados de maior relevância e qualidade.

Ainda, não necessita de dados estruturados - governados por campos delimitados de informações categorizadas. ROSS é capaz de trabalhar e extrair conhecimento de dados desorganizados, que hoje representam mais de 80% do total. São considerados desorganizados todos os dados produzidos por humanos para outros humanos em Linguagem Natural; como artigos, literatura, blogs e até mesmo *tweets*. A Linguagem Natural é governada por princípios lógicos, gramaticais e culturais, e por sua vez apresenta complexidades, ambiguidades e significados implícitos impossíveis de identificação por métodos de computação convencionais.

⁶⁴ BRODKIN, Jon. IBM's Jeopardy-playing machine can now beat human contestants. Network World, 2011.

Antes de estar apto para responder as perguntas propostas, ROSS precisa ser treinado na matéria. Para tal, é alimentado com vasta quantidade de informações provenientes de diversas fontes selecionadas, montando sua bagagem de conhecimento, chamada de *corpus*. A partir de então, começa a correlacionar e organizar a biblioteca recebida. As informações fornecidas para a composição do *corpus* são supervisionadas por humanos, que retiram as fontes mal conceituadas, irrelevantes ou ultrapassadas. Após organizar o *corpus*, ROSS passa por treinamento de Machine Learning para aprender os padrões linguísticos de determinado domínio e aperfeiçoar seu desempenho.

O funcionamento do ROSS pode ser dividido em quatro etapas⁶⁵. A primeira corresponde à observação do objeto, no caso, (i) Análise da Proposição. Diferente de sistema de busca convencionais, que dependem da identificação e correlação de palavras-chave, ROSS examina os elementos do período – sujeito, verbo, objeto – para compreender o papel que assumem e gerar diferentes interpretações semânticas. Pondera se trata-se de uma pergunta ou uma afirmação; se versa sobre um lugar, um número, uma pessoa, etc. Faz isso ao desconstruir a gramática, estrutura e contexto da proposição objeto.

A segunda etapa é a de (ii) Geração de Hipótese. Para cada interpretação gerada, ROSS busca em seu *corpus* informações relacionadas e formula hipóteses. Como ainda não sabe qual das interpretações é a correta, precisa criar hipóteses para todas as possibilidades. Para aumentar suas chances de sucesso, realiza uma análise comparativa com outros períodos presentes em seu banco de dados e elenca as que possuem a maior probabilidade de correspondência. Nessa etapa, quantidade de resultados é mais importante que a qualidade. O programa não pode ignorar nenhuma hipótese, pois existe a possibilidade de aquela ser, entre todas, a correta.

Após formular inúmeras hipóteses, passa para a etapa de (iii) Pontuação de Hipóteses e Evidências. Aqui, ROSS avalia a qualidade de cada hipótese formulada. Para isso, coleta em seu banco de dados evidências positivas e negativas para cada uma; atribuindo, ao final, uma pontuação / peso às possibilidades disponíveis. Essa distribuição de peso se baseia em extenso treinamento prévio por meio de Machine Learning, e considera a qualidade e aplicabilidade da evidência. Para aumentar suas chances de sucesso, procura equiparar a pergunta em questão com soluções passadas

⁶⁵ IBM Watson: The Science Behind an Answer. Disponível em <https://www.youtube.com/watch?v=DywO4zksfXw>. Acessado em 28.09.2017.

que mais se aproximam do problema atual. Aqui, vários algoritmos trabalham em conjunto para aumentar a velocidade do processo.

A etapa final é a de **(iv) Comparação e Classificação**. Após pontuar as hipóteses, se utiliza de sua experiência e combina seus algoritmos para analisar comparativamente a importância, utilidade e peso final de cada hipótese. Ao final, as mais bem avaliadas são compiladas e classificadas em um ranking de Confiabilidade Individual e Comparativa. Caso a Confiabilidade Individual para a resposta não atinja a marca de 50%, é desconsiderada por ROSS. Se acima de 50%, ROSS verifica o quão próxima é a pontuação em comparação à duas ou três respostas mais bem ranqueadas; se muito próxima e inferior, também é desconsiderada. Ao final, ROSS apresenta os resultados com maior probabilidade de estarem corretos.

O desempenho da plataforma é baseado em três pilares, com os seguintes parâmetros: **(i)** Qualidade da Informação Provida - a completude da busca, a precisão nos resultados e sua relevância; **(ii)** Satisfação do Usuário – considerando a facilidade de utilização da plataforma e a confiança nela depositada; e **(iii)** Eficiência da Pesquisa – tempo necessário para que o usuário obtenha uma resposta satisfatória.

Estudo, publicado em janeiro de 2017, foi conduzido pela empresa Blue Hill para testar o desempenho do ROSS em relação à demais ferramentas disponíveis, e revelou resultados impressionantes. A plataforma superou o resultado obtido pelos demais meios de busca em todos os três quesitos apresentados acima.

O teste era voltado a resolução de problemas jurídicos na área de falências, compreendendo a legislação americana. Os participantes do estudo foram separados aleatoriamente em quatro grupos. Cada grupo de participantes ficou limitado à utilização de apenas um sistema de busca, sendo eles: **(i)** Busca Boolean⁶⁶, **(ii)** Busca de Linguagem Natural⁶⁷, **(iii)** Busca Boolean + ROSS e **(iv)** Busca de Linguagem Natural + ROSS.

⁶⁶ Pesquisa Boolean é o tipo de pesquisa que permite que os usuários combinem palavras chaves com termos operadores (e, ou, não, etc.) para produzir resultados mais relevantes. Um exemplo seria a pesquisa que combine “Hotel” E “Brasília”, o que limita resultados da pesquisa somente àqueles que contenham as duas palavras chave.

⁶⁷ É o tipo de pesquisa que se utiliza de linguagem falada comum, como o Português. Nele, é possível se fazer uma pergunta simples, que será analisada pelo banco de dados por meio de uma lógica semântica pré-programada, identificando palavras chave por meio do seu posicionamento no período. Sistemas de busca como Google e Bing são de Linguagem Natural.

Cada participante recebeu sete perguntas que refletiam problemas reais envolvendo a matéria, devendo respondê-las dentro de duas horas. Os participantes possuíam experiência mínima em matéria de falências e nenhuma experiência com os sistemas de buscas disponibilizados. Para comparar o desempenho das ferramentas de busca examinadas e respostas, foram convidados dezesseis profissionais versados na área para comporem painel de avaliação.

No que tange a **(i) Qualidade da Informação Provida**, ROSS superou ambos os sistemas de busca de Linguagem Natural e Boolean, tendo o último apresentado desempenho muito inferior aos demais. De todos os resultados fornecidos pelo ROSS, 37.9% representavam resultados relevantes, contra 25.8 e 33.5% dos demais. Ainda, foi capaz de encontrar 55.8% dos 20 resultados mais relevantes possíveis, contra 31.1 e 52.4%.

No quesito de **(ii) Satisfação do Usuário**, ROSS apresentou avaliação média de 4.9 de 5 nos parâmetros de Facilidade de Uso e Confiança depositada pelo Usuário, contra 3.2 e 3.4 para os sistemas Boolean e de Linguagem Natural, respectivamente.

Por fim, no quesito de **(iii) Eficiência da Pesquisa**, que considera o tempo total gasto para responder todas as perguntas, ROSS também apresentou o melhor resultado. No geral, o tempo médio gasto por todos os grupos foi de 43 minutos. Os que utilizaram ROSS terminaram a tarefa na média de 36.5 minutos, apresentando economia de 30.3% e 22.3% em relação aos sistemas Boolean e de Linguagem Natural, respectivamente.

Existem várias maneiras pelas quais a eficácia da pesquisa pode se relacionar com a rentabilidade de um escritório, especialmente no que tange a perda significativa de receita associada a esse tempo desperdiçado. No geral, horas dedicadas a pesquisa jurídica tendem a não ser passivas de cobrança dos clientes. A Blue Hill estima que um associado médio dedique, em média, 743,6 horas por ano a pesquisas jurídicas, das quais 26% findam como não faturáveis ou não pagas pelos clientes. A redução no tempo dedicado a essa tarefa permite que tais horas sejam realocadas em atividades passíveis de cobrança, aumentando o faturamento ou reduzindo custos.

O crescimento de alternativas de baixo (ou nenhum) custo pressiona os modelos tradicionais de cobrança, ao mesmo tempo que impulsiona a implementação de funcionalidades e recursos mais novos e eficientes; seja por meio da redução do tempo dedicado a pesquisa, retirando

mais valor dos dados jurídicos disponíveis ou removendo a necessidade de identificação, indexação e classificação manual de dados.

2. LawGeex

Diversas empresas dependem de um departamento ou conselho jurídico interno para revisar e aprovar contratos, fechar negócios e manter seu negócio correndo de maneira eficiente. Esses departamentos legais tendem a estar sobrecarregados de trabalho, e atividades como revisão contratual consomem extenso e precioso tempo, geralmente engarrafando procedimentos internos, requisitando foco e atenção que poderiam estar sendo voltados para questões mais sensíveis.

O programa LawGeex é um software que utiliza de algoritmos de Machine Learning de Aprendizado Supervisionado e de análise de textos para ler peças contratuais, sendo capaz de fazer correções, alertas e sugerir alterações com base em políticas e princípios pré-estabelecidos por uma empresa ou escritório, automatizando processos de revisão e aprovação contratual. Foi iniciado em 2014 e já conta com mais de U\$ 9.5 milhões de investimento. Nas palavras de seu CEO, *“LawGeex está transformando operações legais cotidianas ao automatizar a revisão e aprovação de contratos. Nós ajudamos negócios a funcionarem de maneira mais rápida e suave ao remover o “engarrafamento jurídico”⁶⁸*”.

O programa, que já integra tecnologia de Nuvem, possui uma interface limpa e intuitiva, permitindo que os usuários escolham de maneira fácil e rápida - por meio de um *checkbox* - pela presença ou ausência de cláusulas contratuais de interesse. O programa já inclui em seu diretório inúmeras cláusulas contratuais “comuns”, contudo permite que cláusulas complexas e personalizadas sejam desenvolvidas e incorporadas.

O funcionamento da plataforma é muito simples: após estabelecer as cláusulas de interesse, basta arrastar um documento (em formatos .doc, .docx e .pdf) ou imagem para o programa para que esse comece a fazer a análise. O relatório final identifica, organiza e aponta quais cláusulas constam ou não no contrato, grifando passagens suspeitas ou discrepantes.

⁶⁸ PR Newswire – AI Platform LawGeex. Disponível em <http://www.prnewswire.com/news-releases/legal-saas-ai-platform-lawgeex-raises-7-million-in-funding-round-615570484.html>. Acessado em 02.10.2017.

O programa também permite que sejam criados fluxos de comunicação internos, de forma que os relatórios criados possam facilmente correr entre pessoas de diferentes departamentos e níveis hierárquicos para revisão e aprovação, aumentando a eficiência da revisão. Ao identificar resultados alarmantes, o programa escala automaticamente o contrato em questão para análise pelo departamento legal. Além de minimizar riscos por meio de padronização das políticas legais, permite que alterações gerais sejam feitas rapidamente e de maneira centralizada, atingindo todos os departamentos instantaneamente.

Até o momento, fora disponibilizado apenas um pequeno caso de estudo do desempenho e eficiência do programa, realizado pela empresa Bradwatch – Social Media Monitoring. Em seu relatório, reporta ter incorrido em uma economia de 80% no tempo gasto em revisões contratuais e em uma economia de 90% no custo referente ao serviço de revisão contratual, geralmente delegado a escritórios. Contudo, ressalta-se que não foram conduzidos estudos aprofundados sobre a eficiência trazida pelo programa.

3. RavelLaw

RavelLaw é um software desenvolvido por *startup* americana, iniciada por estudantes da Universidade de Stanford, que se utiliza de I.A. para realizar análises estatísticas na área jurídica e extrair valor de dados legais. O programa é capaz de processar Linguagem Natural e extrair conhecimento de dados não estruturados de maneira similar a ROSS. A partir da análise de milhões de casos passados⁶⁹, RavelLaw identifica padrões em resultados e decisões judiciais e fornece a probabilidade de provimento em futuros casos similares, para cada juiz e tribunal; fortalecendo a tomada de determinadas estratégias e permitindo a criação de novas. O programa também auxilia na elaboração de argumentos, por meio de pesquisa analítica de jurisprudência e legislação. O programa é focado em quatro frentes: **(i)** Análise de Juízes, **(ii)** Análise de Tribunais, **(iii)** Análise de Casos e **(iv)** Pesquisa de Casos.

Na Pesquisa, é possível procurar por Juízes, Tribunais, Casos e Legislações, utilizando formato de busca Boolean clássico ou de Linguagem Natural. A pesquisa indica os resultados mais

⁶⁹ A empresa fundou um grande projeto de escaneamento de livros e publicações na Biblioteca de Direito da Universidade de Harvard, chamado de *Free the Law* (“Liberte o Direito”), que irá digitalizar a coleção completa da biblioteca - que conta com mais de 40 milhões de páginas - para aprimorar o desempenho da plataforma.

relevantes – considerando contexto, citações, hierarquia, temporalidade - e apresenta casos relacionados um mapeamento visual. Cada caso é representado como um círculo, cujo tamanho indica o número de vezes que fora citado. Relações entre casos são representadas por linhas que conectam seus respectivos círculos, cuja grossura indica a relevância da relação. A plataforma fornece uma série de filtros (matéria, ato, jurisdição, ano, etc.), permitindo melhor definição do escopo da busca e afinação de resultados.

Na Análise de Juízes e Tribunais, é possível pesquisar por juízes ou órgãos colegiados específicos, seja diretamente pelo nome ou jurisdição. A plataforma fornece a. o Perfil de Juízes – nome, idade, notícias, histórico educacional e profissional; e b. Análise de Atos Judiciais (despachos, decisões interlocutórias, sentenças e acórdãos) – apresentando histórico com número total de cada ato, sua natureza, teor, principais argumentos, citações, divergência em votos e taxas totais de provimento para cada pedido, em porcentagem e integralidade.

Para Análise de Casos, a plataforma possui indicadores de a. Histórico, com volume total de citações de um caso organizadas por ano; b. de Citações Relevantes, que identifica as passagens e páginas mais citadas do caso e as compila por relevância; e também contém c. links para Juízes, Tribunais, artigos e publicações relacionados ao caso.

III. LEGAL LABS – DRA. LUZIA

Os programas apresentados acima foram os pioneiros na aplicação da moderna tecnologia de I.A. a área jurídica. A equipe organizada pelo professor Ricardo os estudou a fundo antes de iniciar o desenvolvimento de seu projeto, analisando a tecnologia utilizada, identificando as soluções que trazem ao mercado, suas vantagens e falhas. Aprendendo o máximo possível com as experiências já conduzidas, visam extrair seus pontos positivos e aplica-los ao seu projeto, que traz solução diversa e inovadora.

O programa desenvolvido pela Legal Labs, nominado *Dra. Luzia*, busca auxiliar o trabalho de servidores públicos a partir da (i) identificação de andamentos processuais, reconhecendo a fase e natureza do andamento, e (ii) geração automática de petições, fornecendo respostas-modelo aos atos processuais identificados, em conjunto com os principais fundamentos aplicáveis ao caso.

Ao automatizar a ponderação e elaboração de soluções processuais com fundamentos adequados, deixa ao advogado somente o trabalho de supervisão da tarefa - verificando sua atuação, identificando e corrigindo eventuais equívocos – e de redação final, adaptando, se necessário, os dados fornecidos em uma narrativa coesa e fluida. Abaixo será apresentado o desenvolvimento do projeto, apresentando objetivos, visões estratégicas, desafios, etapas e técnicas utilizadas.

a. Objetivo e Definição de Escopo

O objetivo do projeto era o de criar software de I.A. capaz de gerar o maior incremento possível na eficiência da justiça, a partir da execução e auxílio de/em atividades mais simples, repetitivas, mecânicas e previsíveis incorridas por procuradores e servidores públicos, desafogando suas rotinas e permitindo a realocação de seu tempo e atenção a casos de média e alta complexidade, que necessitam de verdadeiro raciocínio estratégico e tomada de decisões críticas.

Tratando-se de projeto de *I.A. Restrita*, o primeiro desafio a ser enfrentado pela equipe fora a delimitação do escopo de atuação do programa. Após ponderação, definiu-se que nicho a ser trabalhado seria o de procedimentos de cobrança em execuções fiscais da Fazenda Pública.

Como apresentado, os processos de execução fiscal totalizam 30,4 milhões de casos (38% do acervo processual público), sendo a classe de maior volume processual no país, além de possuírem a maior taxa de congestionamento dentre todos os procedimentos (91%)⁷⁰. Dessa maneira, correspondem a um número substancial de casos marcados por uma alta taxa de ineficiência⁷¹, se revelando como problema público relevante e ótimo alvo de solução.

Soma-se a isso o conhecimento e intimidade do professor Ricardo com área. Atuando como Procurador do Distrito Federal a quase 10 anos, Ricardo está em contato direto com o problema que visa solucionar e conhece pessoalmente as dificuldades enfrentadas pelos servidores. Dessa maneira, é capaz de identificar exatamente que tipo de ferramenta e funcionalidades seriam ideias

⁷⁰ CNJ, Justiça em Números, 2017, op. cit., pg. 108-111.

⁷¹ Notadamente: legislação defasada, cadastros ineficientes dos cobradores públicos, falhas na inscrição da CDA, bases de bens não compartilhadas entre Entes, volume exponencial, arditosas artimanhas de muitos dos grandes devedores, máquinas do Executivo e Judiciário despreparadas para o volume de processos, etc. - Inteligência artificial (IA) aplicada ao direito: como construímos a Dra. Luzia, a primeira plataforma do Brasil com Machine Learning utilizado sobre decisões judiciais. – FERNANDES, Ricardo. Inteligência artificial (IA) aplicada ao direito: como construímos a Dra. Luzia, a primeira plataforma do Brasil com machine learning utilizado sobre decisões judiciais, 2017.

para otimizar o trabalho, ajustando os detalhes do projeto para que se conformem com a demanda desejada.

Não somente, possui o conhecimento necessário para propor as corretas soluções às questões processuais envolvidas. Conhecendo a matéria a fundo, se configura como especialista capaz de dirigir e supervisionar o processo de aprendizado da rede com precisão e presteza, além de averiguar a qualidade do desempenho do programa. A equipe também consta com experientes juristas e advogados, que auxiliam no fornecimento do conhecimento técnico jurídico necessário para otimizar os resultados.

b. Obtenção de Dados

Definido o nicho de atuação do programa, o passo seguinte fora a composição da base de dados necessária para o processo de treinamento da rede neural.

Como salientado, o processo de aprendizado supervisionado pela qual a rede neural é submetida depende da exposição a *exemplos de treinamento*. São eles que fornecem o conhecimento experiencial ao algoritmo para que esse reorganize a configuração de *pesos* em busca de melhores resultados. A formação do banco de dados para treinamento enfrenta basicamente dois desafios: **(i)** a obtenção dos dados em si, e **(ii)** sua organização e formatação.

No que se refere ao primeiro ponto, o desafio encompassa a obtenção de um alto volume de informações diversificadas, relevantes e atualizadas sobre a área objeto - quanto maior a qualidade e quantidade de exemplos, maior o potencial de aprendizado. Felizmente, a equipe não precisou se debruçar sobre a obtenção dessa grande quantidade de dados.

Em razão do princípio da publicidade, órgãos e entes públicos são obrigados a disponibilizar aos cidadãos informações relativas a grande maioria dos processos de maneira gratuita, aberta e irrestrita. Dessa maneira, fora possível obter acesso a rico arcabouço de informações relativas a área objeto do programa sem maiores esforços. Por comportarem grande quantidade de informações relevantes e em formato digital, páginas *web* de órgãos e Tribunais foram utilizadas como a principal fonte de dados.

c. Organização e Pré-processamento de dados

Obtido acesso a banco adequado, passou-se a sua organização e processamento. Isso por que o mero acesso aos dados não satisfaz as necessidades de desenvolvimento - tais informações necessitam ser extraídas e organizadas em formato propício ao aprendizado. Para que um dado “cru” se torne útil em treinamento, é necessário que esse seja estruturado, categorizado e traduzido para uma representação numérica cujo algoritmo consiga compreender. Só então é possível correlacionar os dados e iniciar o trabalho de treinamento.

Por envolver uma enorme quantidade de dados desestruturados referentes a inúmeros processos, tarefas de extração e organização se revelaram trabalhosas e custosas, sendo inviável conduzi-las manualmente. Com isso em mente, a equipe recorreu à utilização da técnica ETL – *Extract, Transform, Load*⁷². Esse procedimento realiza automaticamente, a partir de regras pré-definidas, as tarefas de identificar, extrair, limpar e transformar em massa as informações disponíveis nas fontes públicas, carregando-as para uma base de armazenamento estruturada.

A primeira fase do ETL corresponde à (i) extração dos dados. Nessa, utiliza-se técnica denominada raspagem – do inglês, *scrapping* – que obtém automaticamente informações desejadas de um domínio a partir da análise de seu código fonte, processo similar ao utilizado na extração informações de DJEs e andamentos de Tribunais. O raspador busca, identifica, extrai, agrega e transforma os dados não estruturados em formato passivo de armazenamento organizado, utilizando técnica de Processamento de Linguagem Natural – PNL⁷³.

A etapa seguinte consiste na (ii) transformação dos dados, que fora conduzia simultaneamente à extração para otimizar o processo. Essa fase consiste em um pré-processamento das informações obtidas, transformando-as em corpos textuais bem definidos, além de adequar e estruturar seu formato-fonte ao formato-alvo a ser utilizado pelo algoritmo de aprendizagem⁷⁴. O

⁷² SIMITSIS, A; VASSILIADIS, P.; SELLIS, T. Optimizing ETL processes in data warehouses, in Data Engineering, 2005, pgs. 564–575.

⁷³ Processamento de Linguagem Natural visa transformar texto em características numéricas, formais e estruturadas, abstraindo a estrutura da língua e deixando somente informações relevantes; possibilitando a computadores entender, manipular e compor textos em linguagem natural. Trata-se de tarefa árdua, morosa e que requer conhecimento de especialistas na área envolvida. O nível de complexidade do procedimento depende da quantidade e qualidade dos textos envolvidos. Por se tratar de domínio jurídico, com intrincado vocabulário, fora necessária especial atenção pela equipe.

⁷⁴ Aqui são se utiliza técnica de Processamento de Linguagem Natural denominada triagem de documentos, com intuito de minimizar erros e evitar reprocessamento da base de dados.

formato-alvo escolhido para o projeto foi o JSON, em decorrência de sua capacidade de interpretação cada vez mais universal e a compatibilidade com as diversas tecnologias de bancos de dados não relacionais, permitindo uma maior escalabilidade na utilização dos dados.

Por fim, realiza-se o (iii) carregamento dos dados pré-processados para um bando de dados. Fora utilizado um banco de dados NoSQL⁷⁵, que, a partir de um código de análise sintática do formato JSON, recebe os dados dos lotes extraídos e atualiza os processos ativos de acordo com novos andamentos processuais. Ao final, somavam-se mais de 350 mil processos judiciais em formato JSON, incluindo publicações, andamentos e demais dados.

Antes de prosseguir, os dados carregados foram submetidos a mais formatações, que promovem ganhos em escala e facilitam o processamento computacional envolvido no aprendizado. Os dados foram submetidos a pré-processamentos em linguagem natural de *tokenização*⁷⁶, *normalização textual*⁷⁷, *remoção de stop-words*⁷⁸ e *bag of words*⁷⁹. Depois de carregados os dados estruturados, fora possível realizar uma análise de amplo escopo sobre as informações obtidas, permitindo melhor planejamento estratégico.

⁷⁵ “Nosql,” <http://nosql-database.org/>.

⁷⁶ A *tokenização* consiste na redução de um dado para a menor unidade de informação textual passível de processamento por uma máquina (*token*), encontrando-se os limites de cada palavra em uma frase, mesmo se adjunta a alguma pontuação. A técnica isola o termo, converte-o para letras minúsculas e remove tags HTML/Javascript/CSS, dentre outras. A complexidade do processo é definida pelo idioma em questão – sistemas logográficos como o japonês apresentam maior dificuldade. Por exemplo, a tokenização da frase “Os funcionários chegaram” seria “os” “funcionários” “chegaram”.

⁷⁷ A *normalização textual* é uma complementação à *tokenização*. É subdividida em duas abordagens. A (i) *stemização* consiste na retirada de sufixos dos termos, reduzindo-os a seu radical; exemplo: “gatas” e “gatos” se tornam “gat”. Já a (ii) *lematização* reduz a palavra ao seu lema, que é, para substantivos, sua forma no masculino e no singular, e para verbos, sua forma no infinitivo; por exemplo: “gatas” e “gatos” se tornam “gato”; “tiver” e “tenho” se tornam “ter”. A utilidade dessa técnica consiste na redução de vocabulário e abstração de significado, que possibilitam a retirada de termos, delimitação de domínios, e diminuição de características a serem analisadas por algoritmos de aprendizagem, sendo possível, em documentos normalizados, buscar informações independentemente de flexões ou de quão rica é a morfologia do domínio.

⁷⁸ Esse método consiste em remover palavras muito frequentes, tais como “a”, “de”, “o”, “da”, “que”, “e”, “do” entre outras, irrelevantes no domínio e para a construção do modelo, se apresentando como ruído. A lista de *stop-words* deve ser construída levando em consideração o domínio a ser trabalhado, visto que a relevância de um termo varia dependendo da área e contexto. No caso, especialistas jurídicos foram designados para liderar a elaboração do conjunto de termos relevantes.

⁷⁹ Esse método considera tão somente a presença ou não de um *token* em um documento ou conjunto de documentos (*corpus*), desconsiderando a sua ordem ou função gramatical. Esse método gera uma lista de termos únicos presentes na amostragem analisada e atribui um peso numérico a cada um, dependendo de sua frequência na amostragem. Quanto mais utilizado o termo, maior o peso e maior a relevância atribuída. São utilizadas duas técnicas básicas: (i) Term Frequency, que considera repetições do termo apenas em um documento do *corpus* analisado, delimitando seu contexto; e (ii) Term Frequency – Inverse Document Frequency, que além de considerar aparições em documento singular, faz correlação com sua presença geral no *corpus*.

Inicialmente, foi construído um fluxo processual, contendo os diferentes estados e caminhos possíveis para um processo de execução fiscal, análogo a uma árvore de estados em jogos. Ao todo, foram identificados 29 estados processuais, que poderiam ou não corresponder a “nós” ou classes de petições. Esse trabalho foi desenvolvido primordialmente pelos juristas da equipe.

Visando dar maior impacto ao programa, dentre as classes observadas, foram selecionadas as que correspondiam ao maior número de processos, responsáveis por gerar cerca de 85% da carga semanal dos servidores, e identificadas suas principais características.

d. Amostragem dos Dados

Após a extração, organização e formatação dos dados, foi necessário criar estratégias para coletar eficientemente dados o bastante para o treinamento; garimpando de forma eficiente, dentro do total de documentos obtidos, os mais relevantes para cada classe. A estratégia foi traçada conjuntamente por membros do domínio jurídico e computacional da equipe, por se tratar de problema de cunho universal.

Primeiramente, os especialistas jurídicos separaram pequena amostra dos 350 mil processos, destacando manualmente os termos mais especiais, significativos e recorrentes dentro de cada classe. O objetivo era o de organizar lista contendo expressões regulares baseadas nos termos destacados, para gerar uma sugestão automática de documentos relevantes, acelerando a coleta de amostras.

Os documentos sugeridos eram então analisados manualmente e com supervisão. Caso um documento coletado com base nos termos dos dicionários fosse rejeitado na avaliação manual, era feita atualização nas expressões do dicionário, estreitando os resultados sugeridos. Esse processo foi conduzido até que a equipe julgar o número total de dados coletados suficiente para treinamento. Ao final, foram selecionados 136.129 documentos pertencentes às classes relevantes.

Visto que o treinamento também necessita de amostras não pertencentes às classes relevantes, para que o programa se torne capaz de identificar o que não conhece e aprimore sua capacidade de discernimento, foram adicionadas amostras negativas ao conjunto - cumulando, ao

final, 226.219 documentos para utilização no aprendizado. Desse montante, 60% foi dedicado ao treinamento da rede, e 40% foi reservado para a avaliação de desempenho do modelo gerado⁸⁰.

e. Aprendizado e Resultados

Com suficientes dados organizados relevantes em mãos, a equipe se viu pronta para iniciar o treinamento do programa. Para Dra. Luzia, fora utilizada uma Rede Neural Recorrente multi-camadas. Ao todo, a rede apresentara mais de 19 mil unidades individuais de processamento. Essa fora submetida a processo de aprendizado supervisionado voltado à categorização de processos nas classes relevantes selecionadas. Antes de se iniciar o treinamento, fora necessário definir previamente os hiper-parâmetros de aprendizado⁸¹, que influenciam diretamente no tempo necessário para treinamento e nível final de desempenho do programa.

Feito isso, os modelos foram avaliados utilizando-se 40% do *data set*, e seus resultados foram coletados e dispostos em uma matriz de confusão⁸². A partir de sua análise, fora possível extrair valores e métricas que permitem melhor avaliação dos resultados de cada modelo, como precisão⁸³, revocação / *recall*⁸⁴, medida F1 (F1 Score / f-measure), curva ROC e área em baixo da

⁸⁰ O banco de dados voltado ao treinamento de redes, chamados de *data sets*, são divididos em duas categorias básicas: a de treinamento e a de teste. O *data set* de treinamento tende a corresponder a maior parte dos dados organizados - em torno de 70 a 90% - e é voltado ao treinamento da rede. Os dados restantes são reservados para o *data set* de teste. Esse funciona como selo de aprovação e é utilizado somente ao final do desenvolvimento para testar o desempenho da rede. Após o treinamento, testa-se o funcionamento da rede colocando-a para solucionar problemas relativos aos dados restantes ainda não conhecidos, de forma a se validar sua performance final. Caso o programa não seja capaz de fornecer resultados dentro da precisão mínima requisitada, retorna-se à fase de treinamento, procurando afinar os parâmetros de treinamento e qualidade do *data set*. No caso da Dr. Luzia, os dados para treinamento e teste foram usados na proporção conservadora de 60-40.

⁸¹ Alguns dos parâmetros envolvidos são: (i) Learning Rate: taxa de aprendizado do modelo: quão rápido a rede deve aprender novos conceitos e esquecer antigos; (ii) Batch size: número inteiro que determina quantos documentos simultâneos irão ser treinados; (iii) Optimizer: algoritmo utilizado para otimizar a rede neural; (iv) Epochs: quantas vezes a rede a ser treinada irá se treinar sobre os conjuntos inteiros de dados; (v) Activation: função que decide se uma informação deve ser passada a frente ou não.

⁸² Tipo de tabela que permite a visualização do desempenho de um algoritmo de aprendizado, tipicamente supervisionado. Cada coluna da matriz representa as instâncias de uma classe prevista, enquanto as linhas representam os casos de uma classe real. O nome é originado do fato de que a matriz torna mais fácil verificar se o algoritmo está confundindo duas classes.

⁸³ Corresponde a porcentagem de classificações corretas apresentadas, i.e., o quão boa é a classificação.

⁸⁴ Corresponde a porcentagem de classificações corretas apresentadas em relação a quantidade total de elementos para uma classe, i.e., o quão completa é a classificação.

curva ROC⁸⁵. Os resultados finais para a Rede Neural Multi-camadas foram extremamente satisfatórios, apresentando grau de precisão acima de 99% para a classificação da maioria das classes.

f. Fechamento

O trabalho descrito fora desenvolvido no decorrer de 10 meses. Nesse período, a equipe se revelou capaz de idealizar, estruturar, desenvolver, validar e colocar em produção a primeira plataforma do Brasil capaz de apontar petições a serem utilizadas na movimentação em massa de processos de execução.

A partir de seu *Classificador*, desenvolvido nos modelos de rede neural apresentados, Dra. Luzia reconhece o estado atual de um processo e escolhe, dentre 8 modelos, a petição adequada para dar sequência a seu andamento – sem qualquer intervenção humana. Seu *Processador*, então, busca informações necessárias ao complemento da petição escolhida, como endereços, bens relevantes à execução ou demais dados requeridos pelo juiz em seu despacho ou sentença. Por fim, seu *Gerador de Petições* compila as informações encontradas, adequando-as ao modelo escolhido e o preenchendo. O programa ainda conta com um *dashboard*, que apresenta ao usuário informações relevantes capturadas pelo aprendizado de máquina.

Dessa maneira, Dra. Luzia integra uma nova linha de poderosos softwares jurídicos que prometem revolucionar a rotina e atuação de diversos trabalhadores. Apesar de restrita ao escopo de execuções fiscais, a solução apresentada possui potencial de aplicação em diversas outras áreas do direito e representa somente o início do potencial da tecnologia de I.A. É só uma questão de tempo até que as condições se tornem mais favoráveis a ampliação do seu escopo de atuação. Conforme a Administração pública se modernize e passe a adotar soluções mais modernas de T.I., o ambiente para adoção da tecnologia apenas florescerá.

⁸⁵ Do inglês, *Receiving Operating Characteristic* a curva ROC representação gráfica que ilustra a performance de um sistema de classificação binário conforme variação no limite de discriminação. Já a área em baixo da curva ROC resume o nível de performance a partir da redução para um único número.

IV. IMPACTOS SOCIAIS DA TECNOLOGIA

a. Empregos e Automação

O fenômeno da maquinação, iniciado à época da primeira Revolução Industrial, foi responsável pela criação de novas áreas de atuação laboral e, ao mesmo tempo, fez com que diversas atividades de maior simplicidade se tornassem obsoletas em face das novas tecnologias, resultando em mudanças radicais no sistema produtivo e impactando fortemente a economia mundial. Taxas de produtividade foram elevadas a patamares jamais vistos, custos de produção foram reduzidos, novas funções laborais surgiram e, ao mesmo tempo, outras se viram extintas.

Inicialmente, assim como as primeiras máquinas industriais, as singelas utilidades da I.A. atingiam funções simples e escopos restritos. As previsões estimavam que incremento substancial de sua capacidade era longínquo e que a tecnologia não impactaria significativamente o mercado dentro de futuro próximo. Conquanto, tais prognósticos se revelaram imprecisos. Hoje, não restam dúvidas que tecnologia possui utilidade extremamente ampla, sendo passiva de aplicação em quase todos os campos de atuação laboral; seja auxiliando no exercício de tarefas, tornando-as mais fáceis e eficientes; ou de vez tomando-as para si, excluindo funções do mercado.

A constante expansão da automação e maquinação das cadeias produtivas nos faz questionar quais serão os futuros impactos do crescente avanço tecnológico em nosso cotidiano e relações de trabalho. Ao que tudo indica, a queda dos custos de produção em robótica, comunicação e T.I., o crescimento da cobertura e velocidade da internet e os novos avanços em I.A. nos deixam cada vez mais próximos de tecnologias que rivalizam capacidades humanas; nos colocando próximos a uma revolução global de magnitude jamais vista.

O potencial para a automação é claro e forte, e caso venha a ocorrer rapidamente certamente causará problemas. Países como a China já trazem casos que merecem atenção. O país, responsável por 3% da produção global em 1990, elevou o número para 25% em 2015, e hoje emprega mais de 100 milhões de pessoas na fabricação de produtos, dez vezes mais que os Estados Unidos.

No último ano, empresa de eletrônicos situada no país substituiu incríveis dois terços de seus empregados por robôs, e promete esticar essa margem para noventa por cento nos próximos

anos⁸⁶. Na Tailândia, grupo de 35 empresas investiram mais de 4 bilhões de dólares em I.A. em 2015. Em 2016, a gigante chinesa em produção de eletrônicos, Foxconn, que emprega mais de 1.2 milhões de pessoas, automatizou 60,000 empregos em apenas uma de suas fábricas.

De acordo com a Federação Internacional de Robótica, a venda de robôs na China cresceu mais de 50% em 2011. Globalmente, a venda de robôs alcançou recorde de 166 mil unidades vendidas no mesmo ano, o que representa crescimento anual de 40%⁸⁷. Evidente que a tendência é de que a automação apresente crescimento cada vez maior. Prevê-se que no ritmo atual, inúmeros se virão desempregados nas próximas décadas.

Nesse contexto, várias pesquisas vêm sido conduzidas na tentativa de prever a proporção dos impactos que virão. Estudo realizado pelo Instituto Global McKinsey⁸⁸ aponta que, com a tecnologia atualmente disponível, 60% dos empregos são passíveis de ter 30% de suas atividades automatizadas; ao passo que 5% dos empregos já são totalmente automatizáveis.

No que tange as taxas previstas para efetiva automação de empregos, estudos preveem, para as próximas duas décadas, que nos Estados Unidos estimativa seja em torno de 42,5%, e no Reino Unido, 30%⁸⁹. Para países em desenvolvimento, estudo global realizado pelo Banco Mundial em 2016⁹⁰ estima que a automação atinja incríveis dois terços de todos os empregos nas próximas décadas, chegando a 69% para Índia e 77% para China.

Dentre as áreas laborais mais suscetíveis à automação, se encontram as de fabricação industrial (60%), transporte e armazenamento de produtos (60%), agricultura e pesca (57%),

⁸⁶ Motherboard. The Future will be Automated. 6 de março de 2017. Disponível em https://motherboard.vice.com/en_us/article/this-shanghai-factory-plans-to-replace-all-of-its-human-workers. Acessado em 12.10.2017.

⁸⁷ International Federation of Robotics – IFR. World Robotics Report, 2012. Disponível em <https://ifr.org/ifr-press-releases/news/world-robotics-report-2012>. Acessado em 15.10.2017.

⁸⁸ A Future that Works: Automation, Employment and Productivity; McKinsey Global Institute, 2017. Disponível em http://www.mckinsey.com/~media/McKinsey/Global%20Themes/Digital%20Disruption/Harnessing%20automation%20for%20a%20future%20that%20works/MGI-A-future-that-works_Full-report.ashx; Acessado em 14.8.2017.

⁸⁹ Estudo publicado por Carl Benedikt Frey e Michael A. Osborne, em Setembro de 2013 estima taxa de 47%. Disponível em http://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf. Estudo desenvolvido pela empresa britânica PWC em março de 2017 estima taxa de 38%. Disponível em <http://www.pwc.co.uk/economic-services/ukeo/pwc-uk-economic-outlook-full-report-march-2017-v2.pdf>; acessados em 25.10.2017.

⁹⁰ World Bank Group. Digital Dividends: world development report 2016. Disponível em <http://documents.worldbank.org/curated/en/896971468194972881/pdf/102725-PUB-Replacement-PUBLIC.pdf>. Acessado em 15.8.2017.

vendas e comércio de varejo (53%) e mineração (51%)⁹¹. Por outro lado, os serviços que apresentam menor risco de automação são os educacionais, jurídicos, artísticos, midiáticos e administrativos, todos abaixo de 40% - número nada pequeno.

No que diz respeito à área jurídica, estima-se que 23% a 39% das funções sejam automatizadas nos próximos 10 anos^{92 93}. A automação compreenderia especialmente funções que envolvem trabalho cognitivo rotineiro, como seguir instruções básicas ou executar tarefa mental bem estruturada e previsível, similar ao realizado pela Dra. Luzia. Funções de paralegais e assistentes jurídicos são as mais ameaçadas, com risco de 94% de automação⁹⁴. Advogados permanecerão “seguros” enquanto a engenheiros não encontrarem métodos de ultrapassar requisitos mínimos de criatividade e interação social.

Independente das variações observadas nas taxas previstas dos estudos, é certo que os valores indicados são alarmantes.

Alguns argumentos contra o desemprego em massa podem ser tecidos. Muito se fala que a automação, ao mesmo tempo que erradicará funções, trará novas consigo de forma a reestabelecer o equilíbrio no mercado - o que já observado em outras épocas. Não somente, a tecnologia poderá ser utilizada para acelerar a educação, profissionalização e ingresso de novos agentes no mercado, por meio da criação de professores artificiais, por exemplo. Apesar de as proposições aparentarem válidas de início, deve-se ressaltar que a tecnologia em questão traz consigo nível de ruptura sem precedentes.

A grande maioria dos novos empregos que surgirão estarão enquadrados principalmente em áreas relacionadas a própria implementação, manutenção ou modificação das novas tecnologias. Nesse sentido, áreas de ciência, tecnologia, engenharia e matemática (*STEM*, do inglês) prometem dominar a emergente demanda empregatícia, com predominância de funções como cientistas de

⁹¹ McKinsey Global Institute. A Future that Works: Automation, Employment and Productivity, 2017. Disponível em http://www.mckinsey.com/~media/McKinsey/Global%20Themes/Digital%20Disruption/Harnessing%20automation%20for%20a%20future%20that%20works/MGI-A-future-that-works_Full-report.ashx. Acessado em 14.8.2017.

⁹² *Ibidem*.

⁹³ Deloitte – Developing legal talent: Stepping into the future law firm; fevereiro de 2016. Disponível em <https://www2.deloitte.com/uk/en/pages/audit/articles/developing-legal-talent.html>. Acessado em 16/10/2017.

⁹⁴ A Future that Works: Automation, Employment and Productivity; McKinsey Global Institute; janeiro de 2017; disponível em https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf, pag. 70

dados, analistas de segurança da informação e engenheiros de software; funções de alta capacitação técnica.

A maior parte da força de trabalho atual não atua, ou sequer tem condições de acesso ou de preparação em tais áreas. Visto que as funções mais ameaçadas inicialmente serão as de baixo nível de capacitação, as pessoas deslocadas dificilmente terão alguma chance de ingressarem nas funções emergentes. Ainda, conforme a integração entre humanos e máquinas se fortalece no mercado, o domínio da operacionalização de tais tecnologias representará vantagem competitiva diferenciada. Dessa maneira, as oportunidades que surgirão estarão reservadas a uma minoria desafetada da população.

Trabalhadores removidos do mercado pela automação terão de buscar empregos em áreas que sobrevivam a tecnologia, resultando em uma alta concentração em poucas atividades, e por sua vez, alta concorrência. Mesmo somados a funções realmente novas, impensadas e não relacionadas diretamente a mudança tecnologia, é extremamente improvável que haja uma criação de empregos em quantidade capaz de rivalizar as estimativas de automação citadas, que ultrapassam 50%. Não se nega que novas atividades virão a surgir, aponta-se somente que a proporção entre novas funções em relação as automatizadas será insuficiente para suprir a demanda empregatícia.

Por fim, as estimativas apresentadas levam em conta os níveis tecnológicos atuais. Tenha-se em mente que vivemos na era da tecnologia e informação. Nunca antes o desenvolvimento tecnológico fora tão acelerado; o ritmo tende somente a aumentar nos anos por vir. Novas descobertas e avanços poderão encurtar previsões temporais e alargar as quantitativas, incrementando potencial lesivo em questão. Em alguns anos, é provável que seja mais rápido e barato automatizar uma função do que preparar um humano para executá-la.

b. Implementação: Ritmo e Desafios

Apesar dessas estimativas, deve-se observar que a adoção de tecnologias disruptivas tende a ser gradual. A experiência histórica revela que tais mudanças são lentas e indica que eventual automação em larga escala levaria tempo. Em virtude disso, espera-se que adoção seja mais lenta, especialmente em países em desenvolvimento, marcados por maiores barreiras de entrada a

tecnologia, mão de obra barata e prevalência de funções baseadas em destreza manual; contudo, esses se revelam como os mais ameaçados pela tecnologia, por concentrarem as tarefas mais susceptíveis a automação.

Mesmo amparada em fortes incentivos, como crescimento de médias salariais, escalas de produção e negócios internacionais, a implementação em massa da tecnologia enfrenta dificuldades e desafios especiais, e, para suceder, dependerá de novas descobertas e adaptações estruturais a nível social, econômico e legislativo.

A viabilidade técnica é uma das principais barreiras responsáveis por ditar o ritmo e extensão de sua proliferação. Antes de esbarrar em problemas atinentes à sua integração, a tecnologia necessita ser inventada e adaptada para cada tarefa específica. Apesar de já serem capazes de superar o desempenho humano em algumas funções - especialmente em pesquisa de informações, reconhecimento de padrões, habilidades motoras básicas e navegação – diversas outras ainda estão fora de seu alcance e dependem de avanços.

Eventual implementação definitiva no espaço de trabalho somente ocorrerá quando as máquinas passarem a possuir um nível mínimo de performance e revelarem um custo comparativo vantajoso em relação à contratação laboral. No estado atual, o potencial de automação já é certo para diversos setores, mas o caminho para sua concretude é árduo. Para que tal nível de desempenho seja alcançado, serão necessários anos de desenvolvimento focado na automatização de cada indústria, adaptando a tecnologia às nuances de cada mercado. Inovações substanciais em linguagem natural e capacidades senso-motoras destravariam vasto potencial de automação técnica, acelerando a velocidade da aprendizagem de máquina e ampliando seus campos de atuação.

Ainda, por se tratar de tecnologia de ponta, o custo de desenvolvimento das soluções também se revela fator substancial. Trabalhos em hardware variam desde computadores comuns a complexos e custosos projetos de robótica, que requerem câmeras, sensores e boa mobilidade. Soluções em software, apesar de apresentarem maior vantagem comparativa e menor custo marginal, também requerem substancial investimento inicial em engenharia. Contudo, a tendência é que os custos para ambas as aplicações apenas se vejam reduzidos, e as vantagens econômicas obtidas a longo prazo mais que justificam altos investimentos iniciais.

No decorrer das últimas décadas, o preço de custo para confecção de produtos em robótica tem apresentado queda de 10% ao ano⁹⁵. Caso o ritmo se mantenha, robôs que atualmente custam em torno de U\$ 100.000,00 a 150.000,00, com avançada visão digital e destreza de alta precisão, estarão sendo confeccionados pela metade do preço na próxima década. Não somente, até lá deterão maior arsenal de capacidades e superior nível de inteligência⁹⁶. A disponibilização ao público de plataformas *open-source* de Machine Learning, como TensorFlow e OpenAI, também deixa soluções em software mais acessíveis e baratas. A redução nos custos envolvidos inevitavelmente deixará a tecnologia mais viável, competitiva e atraente.

Aspectos referentes à dinâmica do mercado de trabalho, por sua vez, também irão balizar a transição. A oferta, demanda e custo salarial das atividades laborais irão definir quais atividades serão os primeiros alvos de automação. Não somente, automação afetará diretamente o mercado no decorrer de sua implementação, adicionando ainda mais volatilidade nas decisões estratégicas dos agentes econômicos.

A automação também encontra antagonismo no âmbito da aceitação social. Apesar de a resistência à inovações tecnológicas ter diminuído desde o advento da Revolução Industrial, é certo que emergirá forte e significativa pressão sócio-política em oposição quando um número elevado de pessoas começarem a perder seu trabalho e se tornarem incapazes de encontrar novas fontes de sustento.

Será a primeira vez que uma tecnologia colocará em cheque modelo econômico estabelecido a mais de séculos, que tem a atividade laboral como pilar e motor. Não somente, traz consigo sério risco de agravar a grande desigualdade social existente e de contribuir com aumento dos níveis de violência. Isso por que automação desvincula a prosperidade econômica da criação de empregos, permitindo que a economia cresça enquanto taxas de emprego e renda salarial diminuam.

O crescimento de cadeias produtivas independentes de trabalho humano levará à maior redução de custos em escala da história, permitindo que produtos e serviços sejam disponibilizados

⁹⁵ McKinsey Global Institute - MGI. Disruptive technologies: Advances that will transform life, business, and the global economy, 2013. Disponível em <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/disruptive-technologies>. Acessado em 15.10.2017.

⁹⁶ International Federation of Robotics – IFR. World Robotics Report, 2012. Disponível em <https://ifr.org/ifr-press-releases/news/world-robotics-report-2012>. Acessado em 15.10.2017.

a preços extremamente baixos. Ao mesmo tempo, por retirarem a fonte de renda da maioria da população, uma grande parcela se verá sem condições de acessar tais bens. O medo proveniente da ameaça a seguridade laboral motivará muitos a se oporem à adoção das novas tecnologias ou mesmo a trabalhar em produções automatizadas.

Se quiserem assegurar a aceitação da I.A. e minimizar impactos sociais negativos, governos deverão agir com presteza no desenvolvimento de modelos econômicos alternativos. Uma das propostas promissoras é a implementação de Sistemas de Renda Universal (*Universal Basic Income*), que visa distribuir parte dos lucros gerados pela automação àqueles por ela prejudicados, por meio de compensações mensais incondicionais, de forma a manter máquina econômica ativa e estável. A medida, que não deixa de ser alvo de críticas, poderá ser utilizada como auxílio temporário durante a dolorosa transição, ou adotada integralmente por período indefinido.

Muitos se opõem a sua adoção, apontando que estimularia a improdutividade, causaria inflação descontrolada e que se trata de “medida socialista” disfarçada. Entretanto, projetos pioneiros conduzidos em países como Canadá, Namíbia e Índia⁹⁷, indicam o oposto: pessoas tendem a agregar mais valor à economia quando garantidas rendimento mensal mínimo, que viabiliza pequenos investimentos em novos projetos. Os testes conduzidos também revelaram diminuição da pobreza, criminalidade e desnutrição, assim como crescimento em taxas de educação e saúde. O mencionado risco de inflação, por sua vez, se mostra tolo, visto que o projeto não envolve a criação de novo dinheiro, mas somente a redistribuição de dinheiro já existente. Países como Finlândia, Holanda e Quênia também já iniciaram testes do programa. Resultados serão disponibilizados em futuro próximo, quando concluídos.

Sobre os governos também recairá a responsabilidade de regular a tecnologia - principalmente no que tange eventuais riscos à segurança e responsabilidade por danos. Em particular, tecnologias de I.A. voltadas a aplicações militares e automotivas se encontram em posição extremamente delicada. A expectativa é de que tais aplicações reduzam o número de casualidades e danos materiais emergentes, mas seu sucesso dependerá tão somente do quão consistente e segura se revelar. Falhas em programação e demais problemas técnicos podem resultar em graves consequências. Um mero acidente isolado por ser responsável por engatilhar

⁹⁷ Futurism. Universal Basic Income Programs, 2017. Disponível em <https://futurism.com/images/universal-basic-income-ubi-pilot-programs-around-the-world/>. Acessado em 16.10.2017.

fortes regulações e fomentar forte desconfiança e insegurança na tecnologia, com consequente desincentivo à sua adoção.

Programas aplicados nesses setores também irão, inevitavelmente, se deparar com situações de risco, que exigirão a tomada de difíceis decisões. O problema, no caso, não reside na velocidade com a qual os programas farão o juízo, mas sim no seu mérito. Será necessário que realizem sensíveis julgamentos de custo-benefício envolvendo a segurança e integridade de pessoas, tomando decisões que carregam complexa carga moral e ainda são alvo de intrincada discussão⁹⁸.

Atualmente, fornecedores já se expõem ao risco de responsabilização por eventual defeito ou mal funcionamento de produtos e serviços disponibilizados ao mercado. Antes de permitir sua ampla comercialização e utilização, a legislação deverá sofrer alterações para abarcar as questões emergentes de maneira satisfatória. Pioneirismo é observado nos estados americanos de Nevada, Flórida e Califórnia, que já desenvolvem propostas legislativas receptivas a carros “sem-motorista”⁹⁹. Avanços similares serão necessários em todo o globo e para vários os setores. Por sua vez, a extensão e rapidez da atualização legislativa dependerá diretamente de sua aceitação social, interesse econômico e progresso tecnológico.

Conforme se observa, ao mesmo tempo que verificam-se fatores que propulsionam a aceitação e desenvolvimento da tecnologia, inúmeros outros dificultam e se opõem a sua adoção. Nesse contexto de forças opostas, é necessário ressaltar que em nenhum momento na história a sociedade conseguiu estancar o crescimento tecnológico e barrar sua implementação; as pressões

⁹⁸ No ano de 2016, pesquisadores do MIT elaboraram questionário público envolvendo perguntas sobre qual curso de ação um veículo autônomo deveria tomar em determinadas situações de trânsito - como em caso de falha no sistema, nos freios, ou em situações incomuns - coletando mais de 18 milhões de votos. Em conjunto com professor da Universidade de Carnegie Mellon, desenvolveram programa de I.A. voltado a avaliar situações nas quais um veículo autônomo deveria propositalmente colidir com pessoas, escolhendo a opção mais indicada pelo questionário moral conduzido. Dado que podem surgir inúmeras combinações e casos não elencados no questionário, a I.A. também responde a situações para qual não existe resposta prévia. A ideia é que, independente da situação apresentada, o algoritmo lapidará as intuições de ética coletiva avaliadas, se revelando tão ético quanto a média dos cidadãos comuns entrevistados. Obviamente, não está imune a críticas. Afinal, o programa é enviesado pelas opiniões consideradas, atreladas a grupos sociais, étnicos e econômicos distintos. Um dos problemas encontrados é a hipocrisia nos julgamentos; visto que em diversos casos participantes votaram em sacrificar ocupantes do carro para salvar pedestres, mas manifestam que não entrariam em veículos configurados com tal comportamento. The Outline. What Would the Average Human Do, 2017. Disponível em <https://theoutline.com/post/2401/what-would-the-average-human-do>. Acessado em 17.10.2017.

⁹⁹ As principais determinações das propostas requerem que (i) carros possam ter seu piloto automático desligado e que seja possível que o motorista tome controle do veículo e o conduza por meios próprios; (ii) em caso de falhas no sistema, caso o motorista esteja incapaz de tomar controle do veículo, esse deve ser capaz de parar por completo de maneira segura. Regulações voltadas aos testes dos veículos delimitam sua área limite, e estabelecem a necessidade da presença de motoristas no carro.

econômicas sempre se sobrepuseram e saíram vitoriosas. Isso nos inclina a concluir que a consolidação da I.A. é inevitável, e mera questão de tempo. Em face do progressivo crescimento da automação na sociedade, só resta avaliar como a invasão tecnológica afetará nossas vidas.

c. Preparando-se para Ruptura

i. O Novo Mercado de Trabalho

Em uma época em que o crescimento econômico é pequeno e são baixos os ganhos em produtividade, a nova era da automação liderada por I.A. poderá se revelar como verdadeira benção para a economia mundial. Entretanto, os magníficos ganhos potenciais não vêm sem custo. À luz do evidente impacto que a tecnologia trará, o desafio passa a ser como trabalhadores, líderes políticos e econômicos se articularão de forma a extrair e capturar os efeitos positivos da tecnologia e minimizar ao máximo os negativos. Conforme se salientou, o medo relativo à perda de empregos e ampliação da desigualdade social, somados a constante redução salarial observada nas últimas décadas já estão por criar uma aversão às tendências de globalização e modernização, especialmente em economias desenvolvidas.

A incerteza a respeito do seu e impacto sobre cada setor, país e mercado, assim como seu alcance geográfico e tempo para implementação, faz com que a preparação para eventuais mudanças seja ainda mais complexa. Essa é, contudo, tanto possível como necessária; nunca é tarde para ponderar sobre estratégias e respostas apropriadas. Independente das implicações a longo prazo, homens e mulheres devem compreender que a tecnologia, já a curto e médio prazo, irá alterar suas áreas de atuação de uma maneira de outra. A automação de funções cresce a ritmo acelerado, e aqueles que se revelarem capazes de explorar suas utilidades certamente obterão vantagem competitiva. Para tal, deverão agir com agilidade, flexibilidade e resiliência.

Ao mesmo tempo que será imperioso o domínio de novas tecnologias, será o aprofundamento e especialização em áreas de atuação específicas. Visto que funções simples, repetitivas e previsíveis estarão cada vez mais sendo delegadas a sistemas artificiais inteligentes, as atividades restantes serão as mais complexas e desafiadoras dentro de cada área, reservadas a

profissionais de ponta e com leque especializado de habilidades. O reflexo será um mercado cada vez mais apertado, competitivo e exigente.

No campo jurídico, espera-se que a área da advocacia passe por alterações radicais nos próximos dez anos; não só em virtude das inovações tecnológicas, que forçarão domínio de novo conjunto de habilidades, como pela mudança nas demandas dos clientes, que buscarão serviços mais baratos e rápidos, e nas expectativas de funcionários. A extensão das mudanças dependerá dos tipos de clientes, da área e escopo geográfico de atuação de cada firma.

A tendência geral é que escritórios apresentem menor número de advogados associados, paralegais e secretárias em suas equipes - funções mais ameaçadas - abrindo espaço para cargos de gerente de projetos, executivos de vendas e especialistas em dados e tecnologia. A competição também tende a se acirrar especialmente na área, dada a crescente super-oferta de bacharéis em face da regressiva demanda do mercado¹⁰⁰.

ii. Formação Educacional e Profissional

Conforme gerações mais jovens venham a escolher seus caminhos educacionais e profissionais, será imprescindível que se façam atentos aos fatores que impulsionam a automação e como determinados setores serão afetados. Deverão identificar quais habilidades serão alvo de automação e quais restarão úteis ou complementares, se antecipando em desenvolvê-las¹⁰¹.

O modelo tradicional de ensino é caracterizado pela promoção do desenvolvimento de habilidades básicas comuns – de leitura, redação e aritmética - com intuito de produzir indivíduos idênticos e substituíveis para eventual integração em um sistema administrativo burocrático. Esse modelo não se revela mais eficiente, visto que máquinas têm cada vez mais se apropriado de tais funções.

Por esse motivo, será necessário que sistemas educacionais evoluam em face dos avanços tecnológicos e novas demandas do mercado de trabalho, promovendo ensino de novo conjunto de

¹⁰⁰ Deloitte. Developing Legal Talent: Stepping into the future law firm, 2016. Disponível em <https://www2.deloitte.com/uk/en/pages/audit/articles/developing-legal-talent.html>. Acessado em 5.11.2017.

¹⁰¹ BRYNJOLFSSON, Erik; MCAFEE, Andrew. The second machine age: Work, progress, and prosperity in a time of brilliant technologies, W. W. Norton & Company, 2014.

habilidades básicas, que constituam diferencial e agreguem verdadeiro valor aos futuros trabalhadores. Dentre essas, elencam-se inteligência emocional e capacidade de liderança - desenvolvidas a partir de convívio social - alfabetização digital e, especialmente, criatividade.

O maior desafio que se encontra no desenvolvimento de sistemas inteligentes artificiais é a capacidade de apresentarem criatividade; ou melhor, criatividade útil. Como se sabe, computadores são capazes de combinar aleatoriamente inúmeros elementos pré-existentes e fornecer nova ideia ou conceito, mas esses raramente são bons ou possuem alguma aplicação. Seja pela ausência de empatia ou visão de amplo escopo, falham em compreender que tipos de conceitos serão interessantes aos humanos. São capazes, por exemplo, de criar linhas de texto que rimem, mas incapazes de criar um verdadeiro poema que evoque fortes sentimentos espontaneamente.

É nessa capacidade de idealização prática que reside a uma das grandes vantagens comparativas que possuímos sobre as máquinas. Pessoas conseguem identificar com maior precisão se um novo conceito – uma história, um prato, uma música, um design, uma hipótese - irá agradar ou não outras pessoas, pois possuem um tato emocional e social - que emerge unicamente da experiência de ser humano – que as permitem delimitar o escopo de possibilidades relevantes. Computadores estão longe de serem inúteis, sendo extremamente eficientes em reconhecimento de padrões dentro de seus escopos de programação. Contudo, persistem como ferramentas que fornecem respostas cruas a partir de análises numéricas, sendo incapazes de promoverem novas e interessantes perguntas ou ideias.

Nesse sentido, modelos de ensino que enfatizam o desenvolvimento de características exclusivamente humanas - como o sistema de educação primária Montessori - revelam alto potencial. Dando enfoque em estudo autodirigido, forte engajamento prático com uma variedade de materiais (incluindo plantas e animais), rotinas flexíveis com horários desestruturados, questionamento de regras e proposição de soluções não convencionais para problemas, estimula o desenvolvimento da criatividade, curiosidade e pensamento crítico, fortalecendo habilidades como reconhecimento de padrões em amplo escopo, conceptualização de ideias e comunicação complexa. Esse modelo fora responsável por produzir alunos inovadores como os fundadores da Google, Amazon e Wikipedia.

V. CONCLUSÃO

O judiciário encontra-se hoje distante do almejado devido processo. A celeridade permanece uma promessa, enquanto processos tramitam por anos até encontrarem solução – e por mais alguns até serem concretizados, quando são. A conjuntura atual revela tendência negativa, a cada ano, mais processos se acumulam. Princípios constitucionais perdem seu lustre ao se verem impossibilitados de efetivação, resultando em constante perda de credibilidade do sistema judicial, que se vê atolado em burocracia e morosidade.

A tecnologia de I.A. surge como uma resposta a muito necessária, sendo capaz de aumentar a eficiência no provimento de diferentes tarefas – não só - no serviço público, trazendo números impressionantes em ganhos de produtividade e apresentando real capacidade de diminuir o engarrafamento processual. Soluções como as apresentadas já vêm sendo utilizadas no exterior, trazendo resultados impressionantes e ganhando cada vez mais confiança do mercado.

Projetos como a Dra. Luzia estão em sua infância, compõem a primeira onda de inovações de I.A. no setor jurídico e somente riscam a superfície do que está por vir. O avanço tecnológico hoje se encontra em patamar de crescimento jamais visto na história. Inovações surgem a ritmo cada vez mais acelerado, trazendo consigo novas soluções e desafios. Somando a capacidade de escalabilidade dos programas apresentados às novas descobertas que virão, é imprevisível o potencial de resolução de problemas que as máquinas atingirão nas próximas décadas.

Até lá, rotinas e ambientes de trabalho serão gradualmente alterados. Conforme se observou, serão delegadas às máquinas cada vez mais tarefas, permitindo-se encontrar soluções com maior rapidez e precisão, e liberando profissionais para dedicarem seu tempo a questões realmente desafiadoras e dignas de atenção.

Justamente em virtude do grande poder transformador da tecnologia na esfera trabalhista, grandes desafios restam à frente da humanidade. Conforme máquinas se apropriam cada vez mais de funções antes exclusivamente realizáveis por humanos, depara-se com um altíssimo risco de substituição de trabalhadores em diversa áreas. À medida que novas funções e aplicações sejam desenvolvidas, a tecnologia inundará cada vez mais setores. Como se verificou, não serão afetadas somente atividades tidas como simples, visto que a área jurídica, considerada protegida de automação, já começa a ter parte de suas funções assimiladas pelas máquinas.

Ao mesmo tempo que o potencial da tecnologia pode nos aproximar de uma utópica sociedade automatizada, o acúmulo do poder sobre a tecnologia na mão de poucos pode permitir que aspectos como desemprego, desigualdade social e concentração de renda se exacerbem. Caberá aos reguladores se anteciparem às mudanças o quanto antes. Regulações tendem a ser reativas em sua maioria, abrindo espaço para que malefícios do objeto regulado se instalem fortemente no sistema antes de atacados, dificultando ou até impedindo sua remoção. Independente do caminho que se tome, não há dúvidas de que em 50 anos estaremos vivendo em uma sociedade muito distinta da que hoje conhecemos.

A automação, com suas bênçãos e maldições, criará oportunidade para todos desenvolverem habilidades cujas máquinas têm maior dificuldade de replicar - capacidades sociais, emocionais, de educação, tutoria e criatividade. A viciosa cultura de trabalho que se desenvolveu na modernidade força inúmeras pessoas a dedicarem valioso tempo a tarefas rotineiras e vazias, fazendo que negligenciem importantes aspectos da vida e deixem de explorar essas belas habilidades inatas no seu máximo potencial. Conforme máquinas tomem cada vez mais atividades previsíveis para si, nos aproximamos de um futuro em que estaremos cada vez mais livres para exercer nossa humanidade.

VI. REFERÊNCIAS

ALLEN, Layman. **Symbolic logic: A razor-edged tool for drafting and interpreting legal documents**, 1956.

BARTO, A., POWELL, W., WUNSCH, D. **Reinforcement Learning and Its Relationship to Supervised Learning**, 2004.

BRODKIN, Jon. **IBM's Jeopardy-playing machine can now beat human contestants**. Network World, 2011.

BRYNJOLFSSON, Erik; MCAFEE, Andrew. **The second machine age: Work, progress, and prosperity in a time of brilliant technologies**, W. W. Norton & Company, 2014.

CNJ – **Justiça em Números**, 2017. Disponível em <http://www.cnj.jus.br/files/conteudo/arquivo/2017/09/904f097f215cf19a2838166729516b79.pdf>. Acesso em 10.10.2017.

Deloitte. **Developing Legal Talent: Stepping into the future law firm**, 2016. Disponível em <https://www2.deloitte.com/uk/en/pages/audit/articles/developing-legal-talent.html>. Acessado em 5.11.2017.

DREYFUS, Hubert. **Mind Over Machine**, 1986.

DREYFUS, Hubert. **What Computers Can't Do**, 1972.

ELMAN, Jeffrey L. **Rethinking Innateness: A Connectionist Perspective on Development (Neural Network Modeling and Connectionism)**, 1996.

VCloud News. **Every day Big Data statistics**. Disponível em <http://www.vcloudnews.com/every-day-big-data-statistics-2-5-quintillion-bytes-of-data-created-daily>. Acessado em 15.11.2017.

FERNANDES, Ricardo. **Inteligência artificial (IA) aplicada ao direito: como construímos a Dra. Luzia, a primeira plataforma do Brasil com Machine Learning utilizado sobre decisões judiciais**, 2017.

FREY, Carl; OSBORNE, Michael. **The future of employment: how susceptible are jobs to computerization**, 2013. Disponível em

http://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf.

Acessado em 15.10.2017.

Futurism. **Universal Basic Income Programs**, 2017. Disponível em <https://futurism.com/images/universal-basic-income-ubi-pilot-programs-around-the-world/>.

Acessado em 16.10.2017.

GARDNER, Anne. **The design of a legal analysis program**, 1983.

GOERTZEL B.; PENNACHIN C. **Artificial general intelligence**. Springer, 2007, vol. 2.

HASSABIS, Demis. **AlphaGo Zero: Learning from scratch**, 2017. Disponível em <https://deepmind.com/blog/alphago-zero-learning-scratch/>. Acessado em 15.11.2017.

HOCHREITER, S; SCHMIDHUBER, J. **Long short-term memory**, **Neural computation**, 1997, pgs. 1735-1780.

IBM Watson: **The Science Behind an Answer**. Disponível em <https://www.youtube.com/watch?v=DywO4zksfXw>. Acessado em 28.09.2017.

IDC - **Worldwide Cognitive Systems and Artificial Intelligence Revenues Forecast**. <http://www.idc.com/getdoc.jsp?containerId=prUS41878616>. Acessado em 20.10.2017.

International Federation of Robotics – IFR. **World Robotics Report**, 2012. Disponível em <https://ifr.org/ifr-press-releases/news/world-robotics-report-2012>. Acessado em 15.10.2017.

KOHAVI, Ron; PROVOST, Foster. **Glossary of terms - Machine Learning**, 1998, pgs. 271–274.

KOZA, John R.; BENNETT, Forrest H.; ANDRE, David; KEANE, Martin A. **Automated Design of Both the Topology and Sizing of Analog Electrical Circuits Using Genetic Programming. Artificial Intelligence in Design**, 1996, pgs. 151–170.

KURZWEIL, Ray. **The Singularity is Near**. Viking Press, 2005, p. 260

LIAO, Jing; YAO, Yuan. **Visual Attribute Transfer through Deep Image Analogy**, 2017. Disponível em <https://arxiv.org/pdf/1705.01088.pdf>. Acessado em 25.11.2017.

LOEVINGER, Lee; **Jurimetrics - The Next Step Forward**, 1948.

MCCORDUCK, Pamela, **Machines Who Think** (2a ed.), Natick, MA: A. K. Peters, Ltd., 2004.

McKinsey Global Institute - MGI. **Disruptive technologies: Advances that will transform life, business, and the global economy**, 2013. Disponível em <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/disruptive-technologies>. Acessado em 15.10.2017.

McKinsey Global Institute. **A Future that Works: Automation, Employment and Productivity**, 2017. Disponível em http://www.mckinsey.com/~media/McKinsey/Global%20Themes/Digital%20Disruption/Harnessing%20automation%20for%20a%20future%20that%20works/MGI-A-future-that-works_Full-report.ashx. Acessado em 14.8.2017.

New York Times - **A.I. Is Doing Legal Work. But It Won't Replace Lawyers, Yet**. Disponível em <https://www.nytimes.com/2017/03/19/technology/lawyers-artificial-intelligence.html>. Acessado em 8.10.2017

NIBLETT, Brian. **Computer Science and Law**. 1980.

PFEIFER, R. and BONGARD J. C. How the body shapes the way we think: a new view of intelligence (The MIT Press, 2007).

POERSCH, José. **Simulações Conexionistas: A inteligência artificial moderna**, 2004. Disponível em <http://linguagem.unisul.br/paginas/ensino/pos/linguagem/linguagem-em-discurso/0402/040209.pdf>. Acessado em 26.10.2017.

PR Newswire – **AI Platform LawGeex**. Disponível em <http://www.prnewswire.com/news-releases/legal-saas-ai-platform-lawgeex-raises-7-million-in-funding-round-615570484.html>. Acessado em 02.10.2017.

PWC – **Economic Outlook 2017**. Disponível em <http://www.pwc.co.uk/economic-services/ukey/pwc-uk-economic-outlook-full-report-march-2017-v2.pdf>. Acessado em 14.8.2017.

ROSENBLATT, F. **The perceptron: A probabilistic model for information storage and organization in the brain**, Psychological review, 1958, pg. 386.

SANTORO, Adam. **A simple neural network module for relational reasoning**. Disponível em <https://arxiv.org/abs/1706.01427>. Acessado em 25.11.2017.

SCHAEFFER, Jonathan. **One Jump Ahead: Challenging Human Supremacy in Checkers**, 1997, Ed. 2009, Springer, Capítulo 6.

SERGOT, Marek J. **The British Nationality Act as a logic program**. Communications of the ACM, 1986, pg. 370–386.

SIMITSIS, A, VASSILIADIS, P., SELLIS, T. **Optimizing ETL processes in data warehouses, in Data Engineering**, 2005, pgs. 564–575.

STAMPER, Ronald K. **The LEGOL 1 prototype system and language**; The Computer Journal 20.2 (1977), pgs. 102-108. Knowledge-Based Systems and Legal Applications.

The Outline. **What Would the Average Human Do**, 2017. Disponível em <https://theoutline.com/post/2401/what-would-the-average-human-do>. Acessado em 17.10.2017.

WEBER, Théophane. **Imagination-Augmented Agents for Deep Reinforcement Learning**, 2017. Disponível em <https://arxiv.org/abs/1707.06203>. Acessado em 26.11.2017.

World Bank Group. **Digital Dividends: world development report 2016**. Disponível em <http://documents.worldbank.org/curated/en/896971468194972881/pdf/102725-PUB-Replacement-PUBLIC.pdf>. Acessado em 15.8.2017.